

UNIVERSIDADE FEDERAL DO PARANÁ

ELIZABETE BUGALSKI DE ANDRADE PEIXOTO

DETECÇÃO E IDENTIFICAÇÃO AUTOMÁTICA DE POSTES UTILIZANDO NUVEM
DE PONTOS DO SISTEMA LASER TERRESTRE MÓVEL



CURITIBA

2016

ELIZABETE BUGALSKI DE ANDRADE PEIXOTO

DETECÇÃO E IDENTIFICAÇÃO AUTOMÁTICA DE POSTES UTILIZANDO NUVEM
DE PONTOS DO SISTEMA LASER TERRESTRE MÓVEL

Dissertação apresentada como requisito parcial à
obtenção do grau de Mestre, no Programa de Pós-
Graduação em Ciências Geodésicas, do setor de
Ciências da Terra da Universidade Federal do Paraná.

Orientador: Prof. Dr. Jorge Antônio Silva Centeno.

CURITIBA

2016

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

P379d

Peixoto, Elizabete Bugalski de Andrade

Detecção e identificação automática de postes utilizando nuvem de pontos do sistema laser terrestre móvel [recurso eletrônico] / Elizabete Bugalski de Andrade Peixoto. – Curitiba, 2016.

Dissertação - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas, 2016.

Orientador: Jorge Antonio Silva Centeno .

1. Laser Scanner. 2. Detecção de feições. 3. Redes neurais.. I. Universidade Federal do Paraná. II. Centeno, Jorge Antonio Silva. III. Título.

CDD: 526.8

Bibliotecário: Elias Barbosa da Silva CRB-9/1894

TERMO DE APROVAÇÃO

ELIZABETE BUGALSKI DE ANDRADE PEIXOTO

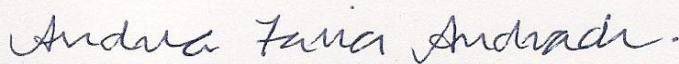
"DETECÇÃO E IDENTIFICAÇÃO AUTOMÁTICA DE POSTES UTILIZANDO NUVEM DE PONTOS DO SISTEMA LASER TERRESTRE MÓVEL"

Dissertação nº 304 aprovada como requisito parcial do grau de Mestre no Programa de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

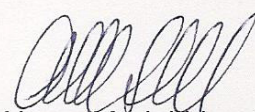
Orientador:



Prof. Dr. Jorge Antonio Silva Centeno
Departamento de Geomática, UFPR



Profª. Drª. Andrea Faria de Andrade
Departamento de Expressão Gráfica, UFPR



Prof. Dr. Alvaro Muriel Lima Machado
Departamento de Geomática, UFPR

Curitiba, 20 de fevereiro de 2017.

Dedico este trabalho a todos aqueles que
diretamente ou indiretamente colaboraram
para sua realização.

AGRADECIMENTOS

Agradeço a Deus, sem Ele não teria chance em escrever essas linhas.

Ao Prof Dr. Jorge Antônio Centeno, meu orientador, pela confiança e dedicação. Responsável pelo constante incentivo ao aprofundamento do assunto. Sempre pronto para ajudar. Só tenho a agradecer um orientador com tanto conhecimento e dedicação aos seus alunos.

À Profa Dra. Cláudia Robbi pelo meu ingresso ao mestrado. Se não fossem as palavras incentivadoras na primeira vez que fui pedir informações sobre o mestrado na Pós Graduação, talvez não tivesse feito.

À Esteio Engenharia e Aerolevantamentos S.A, pelas horas dispensadas para a realização desse trabalho, bem como, todos meus colegas de trabalho que colaboraram com ideias.

Aos funcionários do Programa de Pós-Graduação em Ciências Geodésicas, em especial para Monica Kleuser, que sempre se colocou à disposição para solucionar os problemas e as choradeiras, que normalmente os alunos fazem e somente quem é aluno, sabe que estamos vulneráveis a passar.

Aos meus colegas de curso que durante esses anos, que não foram poucos, me incentivaram nos momentos mais difíceis. Pelos inúmeros trabalhos em equipe. Muito aprendizado, muitos cafés, muita conversa e amigos para uma vida.

Ao meu marido Ronald, que teve um amor incondicional e muita paciência, cuidando da casa e das minhas filhas. Perdi as contas das vezes que não fui a compromissos familiares para estudar ou escrever.

As minhas filhas Ana Carolina e Gabriele que só por existirem já foram um motivo para continuar em frente.

Aos meus amigos verdadeiros.

Não fiz o melhor, mas fiz tudo para
que o melhor fosse feito. Não sou o que
deveria ser, mas não sou o que era antes.
(Martin Luther King).

RESUMO

O crescimento acelerado das cidades apresenta um cenário de aumento populacional e todas as suas consequências. Necessidades com a questão de infraestrutura é cada vez mais notória. Investimentos na construção ou na revitalização de estradas requerem ações tanto públicas quanto privadas e necessitam de projetos que envolvam não só a estrada, mas todo seu entorno. Áreas urbanas são espaços onde as pessoas vivem e necessitam da organização dos elementos que a compõe para bem estar e segurança de todos. Portanto, atualmente qualquer planejamento ou manutenção referente a infraestrutura urbana necessita de dados georreferenciados. Nesse sentido, o objetivo geral dessa dissertação é desenvolver uma metodologia para detectar e identificar postes e placas oriundas de uma nuvem de pontos obtida por um sistema laser móvel terrestre. O sensor *Laser Scanner* utilizado em plataforma móvel fornece uma nuvem de pontos de alta densidade e a possibilidade de obtenção de informações tridimensionais detalhada das feições é entendida como solução para projetos nessa área. O método proposto para detecção é baseado na densidade de pontos 2D, que verifica o local onde há mais acúmulo de pontos e o separa em arquivos individuais. Essa metodologia é vantajosa visto que um dos maiores problemas no tratamento da nuvem de pontos é a atual falta de capacidade de hardware. Alguns experimentos foram realizados visando comparar a rotina de detecção utilizando uma nuvem de pontos sem nenhum tratamento e outra removendo alguns elementos que causaram oclusões. A segmentação por limiarização foi a técnica utilizada para o agrupamento dos pontos e através da morfologia matemática foi possível a detecção dos potenciais postes e placas. Para a identificação dos elementos, os mesmos foram separados em topo e suporte e as variáveis necessárias calculadas para a sua classificação através de uma rede neural artificial. Os resultados dessa pesquisa mostram a eficiência do uso de uma nuvem de pontos para detecção e identificação de feições

Palavras-chave: *Laser Scanner*, Detecção de feições, Redes Neurais.

ABSTRACT

The accelerated growth of cities presents a scenario of population growth and its consequences. Investments in infrastructure become increasingly necessary. Road construction or revitalization requires both public and private actions, requiring plans that involve the road, but also its surroundings. Urban areas are spaces where people live, they need all of their elements organized for their well being and safety. Therefore, any planning or maintenance related to urban infrastructure requires georeferenced data. In this sense, the objective of this dissertation is to develop a methodology to detect and identify poles and road signs through a cloud of points obtained by a mobile terrestrial laser scanning. The Laser Scanner sensor used in mobile platform provides a cloud of high density points and the possibility to obtain detailed three-dimensional information of features, being understood as solution for works in this area. The proposed method of detection is based on the density of 2D points, which verifies the place where there is more accumulation of points and separates it into individual files. This methodology is advantageous since one of the biggest obstacles to the treatment of the point cloud is the current lack of hardware capacity. Some experiments were performed in order to compare the detection routine using a point cloud without any treatment and another removing some elements that caused occlusions. The threshold segmentation was the technique used to group the points, through mathematical morphology it was possible to detect the potential poles and boards. For feature detection they were separated into top and pole, the necessary variables were calculated for their classification by the neural network. The results of this research show the efficiency of using point cloud for feature detection and identification.

Keywords: *Laser Scanner*, Feature Detection, Neural Network.

LISTA DE FIGURAS

FIGURA 1 - DISPOSIÇÃO DOS EQUIPAMENTOS NO AUTOMÓVEL.	26
FIGURA 2 - LASER TERRESTRE MÓVEL UTILIZANDO POSICIONAMENTO GNSS-INS PARA O GEORREFERENCIAMENTO DIRETO DE DADOS DE VARREDURA A LASER.....	31
FIGURA 3 - DMI. (A) DETALHE DO SISTEMA DMI. (B) SISTEMA DMI INSTALADO NA RODA DE UM CARRO (CORTESIA DE ESTEIO).....	32
FIGURA 4 - CAMERAS INSTALADAS NO SISTEMA LASER MOVEL.....	33
FIGURA 5 - (A) RIEGL VMX-450, (B) TRIMBLE MX 8, (C) OPTECH LYNX, (D) TOPCON IP-S2 COMPACT+, (E) STREETMAPPER, (F) DYNASCAN S250, (G) LEICA PEGASUS: ONE (LEICA PEGASUS: ONE, 2013), AND (H) ROAD SCANNER.....	35
FIGURA 6 - EXEMPLOS DE SISTEMAS INSTALADOS EM DIFERENTES PLATAFORMAS COM SUAS RESPECTIVAS APLICAÇÕES.....	37
FIGURA 7 - COMPONENTES DO SISTEMA PEGASUS ONE.....	38
FIGURA 8 - FUNCIONAMENTO DE UM MAPEAMENTO MÓVEL.....	39
FIGURA 9 - INSTALAÇÃO DO SISTEMA E VEÍCULO COM O SISTEMA INSTALADO.....	39
FIGURA 10 - GEORREFERENCIAMENTO ENTRE OS SENSORES EM UM SISTEMA MTLs.....	42
FIGURA 11 - LEVER ARM OFFSETS EM UM SISTEMA MTLs.....	46
FIGURA 12 - TIPOS E DIMENSÕES DOS POSTES DA UFPR.....	49
FIGURA 13 - TIPOS DE PLACAS DE SINALIZAÇÃO.....	50
FIGURA 14 - SISTEMA MTLs DE 2001.....	51
FIGURA 15 - ANÁLISE DA SEGUNDA DERIVADA DA DISTÂNCIA DE UMA LINHA LASER.....	52
FIGURA 16 - SISTEMA CHEN ET AL (2007), MONTADO SOBRE A PLATAFORMA FIXA.....	53
FIGURA 17 - DADOS E RESULTADOS DO SISTEMA CHEN ET AL (2007),.....	54
FIGURA 18 - ETAPAS DO PROCESSAMENTO DA METODOLOGIA DE GOLOVINSKI.....	55
FIGURA 19 - EXEMPLO DE SEGMENTAÇÃO DE UMA FEIÇÃO.....	56

FIGURA 20 - SEPARAÇÃO DA NUVEM DE PONTOS EM BLOCOS.	57
FIGURA 21 - ALGORITMO BASEADO EM PORCENTAGEM.....	58
FIGURA 22 - MODELO DE GRID DE UMA NUVEM DE PONTOS E DETALHE DO PIXEL	59
FIGURA 23 - ETAPAS DE PROCESSAMENTO DA NUVEM DE PONTOS COM O IDW.	59
FIGURA 24 - DETALHE DA NUVEM DE PONTOS E SISTEMA RIEGL MONTADO NO VEÍCULO.	60
FIGURA 25 - ETAPAS DE PROCESSAMENTO DA NUVEM DE PONTOS PARA A CRIAÇÃO DE MAPAS INTELIGENTES.....	61
FIGURA 26 - DETALHE DOS PIXELS DA IMAGEM E SEUS RESPECTIVOS NÍVEIS DE CINZA.....	62
FIGURA 27 - ETAPAS DO PROCESSAMENTO DE IMAGENS	63
FIGURA 28 - ETAPAS DA SEGMENTAÇÃO	64
FIGURA 29 - LIMIAZIZAÇÃO DE UMA IMAGEM MONOCROMÁTICA UTILIZANDO LIMIAZ T	66
FIGURA 30 - RELAÇÃO ENTRE OS ELEMENTOS NA TEORIA DOS CONJUNTOS	68
FIGURA 31 - EXEMPLO DE UMA IMAGEM ORIGINAL, ELEMENTO ESTRUTURANTE E A IMAGEM RESULTANTE APÓS A MORFOLOGIA MATEMÁTICA.....	68
FIGURA 32 - TIPOS DE ELEMENTOS ESTRUTURANTES.....	69
FIGURA 33 -. IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO EROÇÃO (C)	70
FIGURA 34 - IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO DILATAÇÃO (C).	70
FIGURA 35- IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO ABERTURA (C).	71
FIGURA 36 - IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO FECHAMENTO (C).....	71
FIGURA 37 - TIPOS DE CONECTIVIDADE DOS PIXELS EM RELAÇÃO AO PIXEL CENTRAL.....	72
FIGURA 38 - CORRELAÇÃO ENTRE DUAS VARIÁVEIS X1 E X2.....	73
FIGURA 39- REPRESENTAÇÃO SIMPLICADA DE UM NEURÔNIO BIOLÓGICO.	76

FIGURA 40 - REPRESENTAÇÃO SIMPLICADA DE UM NEURÔNIO ARTIFICIAL.	77
FIGURA 41- ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL.....	78
FIGURA 42 - ARQUITETURA DE UMA REDE BACKPROPAGATION	80
FIGURA 43 - COMPONENTES DO SISTEMA PEGASUS ONE.....	81
FIGURA 44 - FUNCIONAMENTO DE UM MAPEAMENTO MÓVEL.....	82
FIGURA 45 - INSTALAÇÃO DO SISTEMA (A) E VEÍCULO COM O SISTEMA INSTALADO (B)	83
FIGURA 46 - SISTEMA LASER TERRESTRE MÓVEL PEGASUS ONE COM INDICAÇÃO DO ÂNGULO CORRETO PARA INSTALAÇÃO	84
FIGURA 47 - FONTE DE ALIMENTAÇÃO.....	85
FIGURA 48 - UNIDADE DE CONTROLE.....	85
FIGURA 49 - MAPA DE LOCALIZAÇÃO.....	86
FIGURA 50 - RESULTADO DA TRAJETÓRIA.....	88
FIGURA 51 - GRÁFICOS DE SEPARAÇÃO COMBINADA	90
FIGURA 52 - TELA DO ARC EXPLORER COM A TRAJETORIA E OS DADOS.	91
FIGURA 53 - ARTICULAÇÃO DE CORTE DAS FOLHAS	93
FIGURA 54 - EXEMPLO DA CLASSIFICAÇÃO DO TERRENO, EDIFICAÇÕES E CARROS.....	94
FIGURA 55 - PERFIL DA CLASSIFICAÇÃO.....	95
FIGURA 56 - EXEMPLO DO PERFILAMENTO DE UMA ESTRUTURA VERTICAL.	95
FIGURA 57 - REPRESENTAÇÃO DOS PONTOS DE UMA ESTRUTURA VERTICAL NUMA MATRIZ.	97
FIGURA 58 - EXEMPLO DO RESULTADO APÓS LIMIAÇÃO DA FOLHA 18.	98
FIGURA 59 - EXEMPLO DE UM ELEMENTO ESTRUTURANTE COM $R=3$	98
FIGURA 60 - ELEMENTOS DETECTADOS APÓS SEGMENTAÇÃO E UM EXEMPLO.....	99
FIGURA 61 - PONTOS DETECTADOS APÓS MORFOLOGIA MATEMÁTICA.....	100
FIGURA 62 - EXEMPLO DE PLACA DETECTADA COM HISTOGRAMA ILUSTRATIVO.....	101
FIGURA 63 - CÁLCULO DO INÍCIO DO SUPORTE E DO INÍCIO DO TOPO DE UMA PLACA.....	102
FIGURA 64 - SUPORTE E TOPO DE UMA PLACA	103

FIGURA 65 - PONTOS LASER DO CORTE TRANSVERSAL DO SUPORTE DE UMA PLACA E O DIÂMETRO CALCULADO POR RANSAC.	104
FIGURA 66 - CIRCUNFERÊNCIAS GERADAS DURANTE O PROCESSO ITERATIVO DO RANSAC	105
FIGURA 67 - TRÊS EXEMPLOS DE TOPO DE OBJETOS COM SEUS RESPECTIVOS VETORES.....	107
FIGURA 68 - PONTOS LASER E IMAGENS DO TOPO DE UM POSTE A DIREITA E DE UMA PLACA A ESQUERDA COM SUAS RESPECTIVAS MATRIZES COM AS COMPONENTES PRINCIPAIS	107
FIGURA 69 - ETAPAS PARA A CRIAÇÃO DA REDE NEURAL.....	108
FIGURA 70 - TIPOS DE POSTES E PLACAS	109
FIGURA 71 - ARQUITETURA DA REDE NEURAL.....	111
FIGURA 72 - EXEMPLO DE OCLUSÃO DEVIDO AOS CARROS ESTACIONADOS E DETALHE DE UM POSTE QUE TEVE SUA BASE OMITIDA - FOLHA 16	117
FIGURA 73 - EXEMPLO DE OCLUSÃO SOLUCIONADA COM O GRID REGULAR GERADO A PARTIR DA SUPERFÍCIE DO MODELO DIGITAL DO TERRENO- FOLHA 16.....	117
FIGURA 74 - ELEMENTOS DETECTADOS NO CAMPUS E NOS EXPERIMENTOS 1 E 2 (FOLHA3).....	119
FIGURA 75 - ELEMENTO POSTE TIPO 4 APRESENTADO DE FORMAS DIFERENTES.....	121
FIGURA 76 - ELEMENTOS DETECTADOS COM POSSÍVEIS PROBLEMAS PARA A REDE NEURAL.	122
FIGURA 77 - DISTRIBUIÇÃO HORIZONTAL DOS CENTROIDES DOS ELEMENTOS DETECTADOS.....	122
FIGURA 78 - ELEMENTOS VERTICAIS PRÓXIMOS QUE NA DETECÇÃO FICARAM DUPLICADOS.....	123
FIGURA 79 - ARQUITETURA DA RNA.....	126
FIGURA 80 - EXEMPLOS DE ALGUNS ELEMENTOS QUE NAO FORAM CLASSIFICADOS CORRETAMENTE.....	132

LISTA DE GRÁFICOS

GRÁFICO 1 - DESEMPENHO DE TREINAMENTO DA REDE.....	113
GRÁFICO 2 - REGRESSÃO LINEAR DA REDE	113
GRÁFICO 3 - QUANTIDADE DE ELEMENTOS POR CLASSE.....	124
GRÁFICO 4 - QUANTIDADE E PORCENTAGEM DOS ELEMENTOS PARA TREINAMENTO POR CLASSE	125
GRÁFICO 5 - DESEMPENHO DA VALIDAÇÃO QUANTO A FUNÇÃO DE ATIVAÇÃO	127
GRÁFICO 6 - REGRESSÃO QUANTO A FUNÇÃO DE ATIVAÇÃO.....	129

LISTA DE TABELAS

TABELA 1 - DESEMPENHO DO IMU DURANTE A INTERRUPÇÃO DO GNSS	44
TABELA 2 - EQUIVALENCIA ENTRE OS NEURÔNIOS	76
TABELA 3 - FUNÇÕES DE ATIVAÇÃO	77
TABELA 4 - RESULTADO DA DETECÇÃO DE POSTES OBTIDO PELO EXPERIMENTO 1 E 2 E EM COMPARAÇÃO COM AS MEDIDAS "REAIS" NO CAMPUS.	120
TABELA 5 - MATRIZ DE CONFUSÃO DOS ELEMENTOS DETECTADOS NO EXPERIMENTO 1	121
TABELA 6 - RESULTADOS DE PRECISÃO, SENSIBILIDADE DOS EXPERIMENTOS.....	121
TABELA 7 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS DAS CLASSES EM 100% DO CONJUNTO DE 220 ELEMENTOS.....	130
TABELA 8 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE EM 100% DO CONJUNTO DE 220 ELEMENTOS.	130
TABELA 9 - RESULTADO DE PRECISÃO E SENSIBILIDADE DO CONJUNTO DE 220 ELEMENTOS	131
TABELA 10 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS POR CLASSE EM 100% DO CONJUNTO DE 152 ELEMENTOS COM TODAS AS VARIÁVEIS.....	135
TABELA 11 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE EM 100% DO CONJUNTO DE 152 ELEMENTOS COM TODAS AS VARIÁVEIS.	135
TABELA 12 - RESULTADO DE PRECISÃO, SENSIBILIDADE E ACURACIDADE DO CONJUNTO DE 152 ELEMENTOS COM TODAS AS VARIÁVEIS. ...	136
TABELA 13 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS CONSI-DERANDO APENAS ALTURA E RAIO.....	137
TABELA 14 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE CONSI-DERANDO APENAS ALTURA E RAIO.....	137
TABELA 15 - RESULTADO DE PRECISÃO E SENSIBILIDADE CONSIDERANDO APENAS ALTURA E RAIO.	138

TABELA 16 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS CONSIDERANDO APENAS COMPONENTES PRINCIPAIS.....	138
TABELA 17 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE CONSIDERANDO APENAS COMPONENTES PRINCIPAIS.	138
TABELA 18 - RESULTADO DE PRECISÃO E SENSIBILIDADE CONSIDERANDO APENAS COMPONENTES PRINCIPAIS.	139

LISTA DE ABREVIATURAS E SIGLAS

2D	- Duas dimensões
3D	- Três dimensões
ABNT	- Associação Brasileira de Normas Técnicas
ADASs	- Advanced Driver Assistance Systems
AGL	- Acima do nível do solo
ALS	- Airborne laser scanning
ASCII	- American Standard Code for Information Interchange
DEM	- Digital Elevation Model
DGPS	- Differential Global Positioning System
DSM	- Digital Surface Model
DTM	- Digital Terrain Model
FOOTPRINT	- Tamanho do pulso no solo
FOV	- Field Of View
GIS	- Geographic Information System
GLONASS	- <i>Globalnaya navigatsionnaya sputnikovaya sistema</i>
GNSS	- Global Navigation Satellite System
GPS	- Global Positioning System
HADMs	- High Accuracy Driving Maps
HISS	- Hybrid Inertial Survey System
IDAS	- Intelligent Driving Assistant Systems
IDW	- Inverse distance weighted
IMU	- Inertial Measurement Unit
INS	- Inertial Navigation System
LASER	- Light Amplification by Stimulated Emission of Radiation
LiDAR	- Light Detection And Ranging
LSM	- Least Squares Matching
MLS	- Mobile Laser Scanning
MMS	- Mobile Mapping System
MTLS	- Mobile Terrestrial Laser Scanning
PCA	- Principal Components Analysis
POS	- Position and Orientation System

PPP	- Precise Point Positioning
PPR	- Pulse Repetition Rate
QA	- Quality Assurance
QC	- Quality Control
RANSAC	- RANdom SAmple Consensus
RMSE	- Root Mean Squared Error
RTK	- Real Time Kinematik
SP	- Static Position
SVM	- Support Vector Machine
TIN	- Triangular Irregular Network
TLS	- Terrestrial Laser Scanning
VMS	- Velocity measurement system

SUMÁRIO

1	INTRODUÇÃO	20
1.1	OBJETIVOS	22
1.1.1	Objetivo Geral	22
1.1.2	Objetivos Específicos	22
1.2	JUSTIFICATIVA.....	22
2	REVISÃO DE LITERATURA.....	24
2.1	SISTEMA LASER	24
2.1.1	Funcionamento.....	25
2.2	LASER TERRESTRE MÓVEL	26
2.2.1	GNSS	27
2.2.2	IMU.....	27
2.2.3	Filtro de Kalman	28
2.2.4	DMI.....	31
2.2.5	Câmeras Digitais	33
2.2.6	Principais sistemas existentes no mercado.....	34
2.2.7	Aplicações do MTLS.....	36
2.3	SISTEMA TERRESTRE MÓVEL PEGASUS ONE	38
2.4	GEORREFERENCIAMENTO E EQUAÇÃO DE POSICIONAMENTO DO MTLS	40
2.5	PRECISÃO E FONTE DE ERROS	44
2.6	COMPARAÇÃO DO SISTEMA TERRESTRE MÓVEL COM O SISTEMA AÉREO.....	46
2.6.1	Principais similaridades	46
2.6.2	Principais diferenças	47
2.7	MOBILIÁRIO URBANO.....	48
2.8	DETECÇÃO DE POSTES E PLACAS.	50
2.9	PROCESSAMENTO DIGITAL DE IMAGENS.....	62
2.9.1	Funções por pixel	63
2.9.2	Classificação com Redes Neurais.....	75
3	MATERIAIS E MÉTODOS.....	81
3.1	MATERIAIS.....	81

3.1.1	Sistema terrestre móvel Pegasus One	81
3.1.2	Área de Estudo.....	86
3.1.3	Coleta de dados	87
3.2	MÉTODOS.....	89
3.2.1	Pré-processamento	89
3.2.2	Deteção de elementos verticais.....	92
3.2.3	Agregação de pixels.....	98
3.2.4	Cálculo de parâmetros geométricos.....	100
3.2.5	Classificação com redes neurais.....	108
3.3	AVALIAÇÃO DOS DADOS DE DETECÇÃO.	114
4	RESULTADOS E DISCUSSÕES	116
4.1	AQUISIÇÃO DOS DADOS.....	116
4.2	DETECÇÃO DOS POSTES E PLACAS	118
4.3	IDENTIFICAÇÃO DOS ELEMENTOS DETECTADOS	123
4.3.1	Coleta e preparo dos dados	123
4.3.2	Criação da RNA	125
4.3.3	Treinamento, validação e aplicação da RNA.....	126
5	CONCLUSÕES	140
	ANEXO 1 - MONOGRAFIA RBMC UFPR	142
	ANEXO 2 - DISTRIBUIÇÃO HORIZONTAL DOS CENTROIDES DOS ELEMENTOS DETECTADOS POR FOLHA.....	144
	REFERÊNCIAS.....	147

1 INTRODUÇÃO

Com o crescimento urbano e consequentemente aumento de veículos nas estradas, os investimentos em infraestrutura tem sido alvo de estudo em todos os países. A conexão entre cidades, pessoas ou até mesmo serviços, faz que a mobilidade desempenhe um papel vital no desenvolvimento de uma cidade. A Política Nacional de Mobilidade Urbana (Lei nº 12.587/2012) determinou que todos os municípios do País com mais de 20 mil habitantes tenham seus planos de mobilidade para obterem recursos do Governo Federal.

A evolução da malha viária não possui a velocidade necessária para acompanhar a expansão desse crescimento, logo a sinalização assume uma responsabilidade maior quanto a segurança viária. Para isso, algumas cidades já percebendo esse problema, têm periodicamente realizado pesquisas e projetos de levantamentos viários que analisam o desenvolvimento de projetos executivos de geometria, sinalização horizontal, vertical, de semáforos e mobiliário urbano para melhoria no âmbito urbano. Os dados pesquisados além de serem utilizados para a manutenção e revitalização das vias são utilizados como ferramentas para a administração pública.

O mobiliário urbano interfere na imagem que as pessoas tem de suas cidades. O manual da cidade de Londres, *Streets for All*, apresenta uma série de recomendações sobre a implantação e o desenho do mobiliário urbano com objetivo de tornar as ruas atrativas, seguras e agradáveis aos usuários, uma vez que a preferência das pessoas por determinados espaços é afetada, entre outros aspectos, pelos elementos urbanos (LONDON, 2000). Portanto, apesar de elementos como hidrantes, pontos de ônibus, postes de iluminação, postes de rede elétrica, postes de sinalização, bancos, não apresentarem importância para muitas pessoas, eles fazem parte de um cenário e são peças determinantes num projeto de revitalização urbana.

Conforme a Confederação Nacional da Indústria, o investimento do Brasil em infraestrutura é de 2% do PIB há mais de duas décadas. Os estudos mostram que a taxa de investimento deveria ser no mínimo de 3% para suportar o crescimento das cidades. São duas décadas acumulando um déficit de 1% que para solucionar demandará ações do setor público e também do setor privado.

A inserção de novas tecnologias tem como objetivo viabilizar financeiramente projetos em infraestrutura, bem como, reduzir o tempo de obras e torná-las mais seguras. Atualmente os projetos são quase todos realizados manualmente, apenas com o auxílio de um *smartphone* ou *tablet*. Além de ser um trabalho demorado e oneroso, pode ser perigoso e causar acidentes quando não sinalizado.

Considerando os fatos relatados, o uso do sensoriamento remoto pode auxiliar nos projetos urbanos. Como os dados são obtidos por um sensor que não está em contato com o alvo, torna-se vantajoso. O levantamento das pinturas de faixas, verificação de rupturas no pavimento, interferências nas estradas são exemplos de atividades perigosas quando obtidas por topógrafos com técnicas convencionais. A transformação de um cenário urbano 2D em 3D fornece uma gama de informações importantes para a tomada de decisão, desde o reconhecimento de objetos como postes e placas até a vinculação de dados que podem ser cruzados e gerar determinada solução para uma cidade.

A proposta deste trabalho é desenvolver uma rotina capaz de detectar e identificar postes e placas oriundos de uma varredura laser scanner obtidos com um sistema laser terrestre móvel realizado no *campus* da Universidade Federal do Paraná, no Centro Politécnico. A área de estudo simula um ambiente urbano, apresentando todos os possíveis obstáculos que podem ser encontrados numa estrada. Árvores, carros, edificações e o Modelo Digital do Terreno foram filtrados para que a maioria dos postes e placas fosse detectada.

Sendo assim, essa dissertação está organizada em capítulos, onde neste primeiro capítulo é apresentada a introdução, os objetivos e a justificativa; posteriormente no segundo capítulo uma revisão bibliográfica apresentando os fundamentos teóricos e os principais estudos referentes ao tema. No terceiro capítulo os materiais e métodos apresentando todos os equipamentos, bem como, a descrição da metodologia empregada. No quarto capítulo foram apresentados os resultados e análises e no último capítulo as considerações finais.

1.1 OBJETIVOS

A seguir são apresentados o objetivo geral e os objetivos específicos a serem alcançados com esta pesquisa.

1.1.1 Objetivo Geral

O objetivo geral desta pesquisa consiste em desenvolver uma rotina para a detecção e identificação automática de postes e placas a partir de uma nuvem de pontos 3D capturada por um sistema laser terrestre móvel.

1.1.2 Objetivos Específicos

Os objetivos específicos para o desenvolvimento da metodologia são:

1. Desenvolver uma rotina na plataforma MATLAB que detecte a localização dos postes e placas;
2. Classificar os tipos de postes e placas conforme suas características e forma;
3. Apresentar uma análise quantitativa da detecção de postes e placas;
4. Apresentar uma análise das redes neurais para a classificação de postes e placas.

1.2 JUSTIFICATIVA

O LIDAR é uma tecnologia mundial e está em constante atualização. Novas possibilidades são rapidamente incorporadas. É conhecido por ser capaz de fazer levantamentos de grandes áreas em um curto período de tempo e de forma precisa comparada a métodos de levantamentos convencionais. Sua popularização é devido ao fato de fornecer uma grande quantidade de informações tridimensionais e fornecer modelos digitais de superfície com rapidez e eficiência.

Por ser um sensor remoto, está sendo utilizado em larga escala para capturar dados tridimensionais para projetos planialtimétricos de cidades inteiras que antes só eram realizados com processos fotogramétricos. Com isso, as cidades possuem o controle de crescimento vertical e horizontal para aumentar a

arrecadação tributária, o controle de áreas verdes e até para a prática de ações sociais com a delimitação de áreas de baixa renda.

Atualmente os sistemas LIDAR podem ser divididos em duas categorias: os aéreos e os terrestres. Os sistemas que são embarcados em aeronaves são indicados para grandes áreas pelo alto custo operacional de um voo. Para o detalhamento de objetos é necessário um planejamento com faixas em sentidos e ângulos diferentes, ficando assim mais caro. Os terrestres são indicados para pequenas áreas ou para áreas lineares, como estradas ou trilhos de trem. Dividem-se em estáticos e móveis.

Os sistemas terrestres estáticos possuem um sensor que captura com alta resolução, onde é possível caracterizar uma superfície com grande detalhamento. Os sistemas estáticos tornaram-se pouco produtivos para levantamento de estradas, por necessitar de várias tomadas e estarem sujeitos a vibrações e vento durante o levantamento, bem como, necessitar que a estrada seja parcialmente fechada, onde nem sempre é possível. Nesse sentido, surgiram os sistemas móveis que foram especialmente projetados para levantamento de estradas. Dada as vantagens dos sistemas móveis em mapear rapidamente uma estrada sem a necessidade de obstrução ou de uma grande equipe de pessoas, eles também oferecem segurança.

A metodologia em mapear infraestrutura urbana com o sistema laser terrestre móvel ainda está em evolução no Brasil. Sua maior vantagem é a obtenção de dados tridimensionais com alta densidade de pontos que possibilitam o detalhamento de uma feição. Processos fotogramétricos convencionais não possibilitam esse detalhamento, bem como, os sistemas laser aéreo não fornecem a quantidade de pontos suficiente para detectar pequenas feições.

Neste sentido, existem demandas nas questões de software e hardware para que a alta quantidade de pontos torne a tecnologia viável. Outros países já vêm utilizando os sistemas móveis para projetos de cidades, apresentando resultados satisfatórios. Porém a necessidade na questão de software ainda é presente. Ferramentas que consigam manipular o grande volume de dados e extrair pequenas feições é o objetivo a ser atingido.

Dado o exposto, este trabalho se justifica sua importância, pois existe uma demanda e poucos recursos quanto a pesquisa e investimentos nessa área.

2 REVISÃO DE LITERATURA

Este capítulo apresenta os conceitos básicos dos temas relacionados com o desenvolvimento dessa dissertação. Eles incluem conceitos do funcionamento de sistemas LASER scanner terrestre móvel, processamento de nuvens de pontos e redes neurais para classificação.

2.1 SISTEMA LASER

O termo *LASER scanner* designa uma tecnologia de coleta de dados tridimensionais que utiliza um sistema de varredura com raios LASER. O sistema utiliza o mesmo princípio de uma estação total, ou seja, medições de ângulos e distâncias para o posicionamento 3D, diferenciando na quantidade de pontos captados e na velocidade de coleta dos dados. O sistema é composto por três componentes básicos: uma unidade de medição LASER, um sistema de varredura optomecânico e uma unidade de registro de medição de apoio e dividem-se em estáticos e dinâmicos. (WEHR e LOHR, 1999). Típicos exemplos de sistemas estáticos são os sistemas terrestres, geralmente instalados em tripés e usados para levantamentos detalhados de objetos a curta distância. Exemplos de sistemas móveis tradicionais são os sistemas aerotransportados, instalados em aviões ou helicópteros, usados para cobrir extensas áreas.

Os sistemas *LASER scanner* móveis, conhecidos internacionalmente como *Mobile Laser Scanning* (MLS) ou *Mobile Terrestrial Laser Scanning* (MTLS) são sistemas dinâmicos, instalados em carros, com maior frequência, porém podem ser instalados também em barcos e trens (HOOVER, 2012). Os sistemas móveis entraram no mercado no início dos anos 2000, com o objetivo de levantar áreas com precisão superior ao levantamento aéreo e com vantagem em coletar uma quantidade de pontos muito superior que um levantamento aéreo.

A popularização do sistema de *LASER scanner* não ocorreu na mesma proporção que a evolução tecnológica. Anualmente, novos equipamentos são lançados no mercado, tanto aéreos como terrestres. Os conceitos básicos da tecnologia se mantêm inalterados, apresentando mudanças na questão da frequência de operação, ou seja, um maior detalhamento ou autonomia para voos mais altos que resultaria em economia no levantamento de grandes áreas. De 2001

até hoje a capacidade de emissão de pontos aumentou aproximadamente quarenta vezes, por outro lado, a viabilidade econômica para adquirir esses equipamentos se manteve restrita por seu alto custo, independente do sistema utilizado.

2.1.1 Funcionamento

O objetivo básico de um *LASER scanner* é a medição de coordenadas tridimensionais de pontos sobre uma superfície. Para isto, pulsos de LASER são emitidos pelo sistema e com auxílio de um espelho de varredura são direcionados, atingindo a superfície dos objetos em vários pontos. Estes objetos refletem o pulso incidente e parte do pulso volta para o sistema. Com isto, a distância entre o sensor e o objeto é determinada através do intervalo de tempo entre a emissão e a reflexão (retorno) do pulso. (BALTSAVIAS, 1999).

Para medir a distância, é registrado o tempo de ida e volta do pulso LASER entre o sensor e a superfície. A medição entre a emissão e a captação do pulso deve ser precisa. A distância pode ser medida pela EQUAÇÃO 1.

$$R = \frac{1}{2} \times c \times dt \quad (1)$$

onde: R=distância (range);
 c=velocidade da luz;
 dt=intervalo de tempo entre emissão e registro do pulso refletido.

Atualmente os sensores a LASER podem ser pulsados ou de onda contínua, e normalmente possuem uma cabeça giratória capaz de coletar pontos em 360 graus. Através do movimento do veículo em conjunto com a varredura do sensor, permite que o perfilamento tenha uma boa área de abrangência. (NCHRP, 2013).

Os sensores também fornecem um valor de intensidade do sinal, que é o grau de reflectância que os elementos que pertencem a superfície possuem. Ele é importante para distinguir objetos da nuvem de pontos e dependendo do sensor possui características diferentes que resultarão em valores diferentes. Nos casos onde são agrupados levantamentos oriundos de sistemas diferentes será necessário


um procedimento de normalização para corrigir essas diferenças. Essa normalização pode ser realizada pelos softwares comerciais de manipulação de dados laser, bem como, através de uma rotina de programação.

2.2 LASER TERRESTRE MÓVEL

Um sistema de laser terrestre móvel consiste, no mínimo, de um sensor laser, um GNSS e um INS, montados numa plataforma móvel, que normalmente é um automóvel do tipo utilitário. Em alguns casos e dependendo da finalidade, o sistema pode ser instalado em trens, barcos ou mochilas.

O posicionamento do sistema laser terrestre móvel baseia-se na combinação de sistemas globais de navegação por satélite (GNSS - *Global Navigation Satellite System*) e de um sistema de navegação inercial (INS- *Inertial Navigation System*), tornando esses dois equipamentos essenciais no sistema. Alguns sistemas com o objetivo de aumentar a precisão no posicionamento utilizam também um instrumento de medição por distância, mais conhecido como DMI (*Distance Measurement Instrument*) fixado na roda do automóvel. Os equipamentos estão dispostos no automóvel conforme FIGURA 1.

FIGURA 1 - DISPOSIÇÃO DOS EQUIPAMENTOS NO AUTOMÓVEL.



FONTE: Adaptado NCHRP (2013).

A precisão da medição depende dos equipamentos utilizados, bem como, a forma de coleta dos dados. O conjunto de medições de apoio, os dados do INS e do GNSS diferencial são coletados e armazenados simultaneamente à medição da distância pelo sistema LASER.

2.2.1 GNSS

O GNSS compreende uma comunidade de sistemas que fazem parte basicamente dois tipos de sistemas de navegação, o sistema de posicionamento americano GPS (Global Positioning System) e o sistema russo GLONASS (*Globalnaya navigatsionnaya sputnikovaya sistema*). O GNSS permite calcular o posicionamento do usuário com um receptor que recebe os sinais emitidos por diferentes satélites em órbita em torno da Terra. Através da utilização de uma estação base e um receptor de dupla frequência é possível alcançar uma precisão absoluta de 2 a 5 cm. (HAKLI & KAIVULA, 2005). O GNSS possui alta precisão em lugares abertos que estejam livres de vegetações ou edifícios que causam degradação ou multicaminhamento do sinal. Os receptores GNSS fornecem três observações para os sistemas de LASER *scanner* móveis: tempo, posição e velocidade. As informações de posição e velocidade são fornecidas para o computador e para o IMU.

2.2.2 IMU

O IMU consiste em acelerômetros e giroscópios e fornece as informações de orientação (*roll*, *pitch* e *heading*) do sistema durante o levantamento e auxilia no posicionamento quando a qualidade do GNSS degrada. O GNSS fornece informação posicional na faixa de 1-10 Hz e o IMU a orientação na faixa de 100-2000 Hz, ou seja, quanto maior a velocidade do veículo, mais importante será a informação do IMU. (NCHRP, 2013).

À medida que o posicionamento do GNSS se degrada, a IMU começará a gerenciar as informações de posicionamento e orientação usando um esquema de filtragem, que combina todas as medições do movimento do veículo para a correta geolocalização. Dependendo da precisão da IMU, ele pode manter pontos precisos e georreferenciar uma nuvem de pontos sem o auxílio do posicionamento GNSS, durante longos períodos de tempo. (NCHR, 2013).

Um sistema de navegação inercial (INS) é formado pela IMU e por um computador de navegação. Neste caso, trata-se de um sistema capaz de identificar um padrão de movimento, proporcionando dados de velocidade e posicionamento para controlar a atitude e direção.

2.2.3 Filtro de Kalmann

Filtro de Kalmann é um método matemático capaz de estimar valores próximos ao real a partir de medições realizadas ao longo do tempo, com ruídos e incertezas. É um algoritmo recursivo simples e eficiente. Tem por objetivo obter a saída do sistema estimada a cada instante e da melhor forma possível.

Essa característica o torna um algoritmo muito utilizado para amenizar problemas nos sistemas de posicionamento. Para a aplicação do filtro de Kalman é necessário seguir os passos: (AQUINO e ARAUJO, 2010).

Inicialmente o sistema é modelado através de uma equação linear, conforme a EQUAÇÃO 2, onde X é a variável do sistema, a é a constante e w é a perturbação do sistema, conhecido também como ruído branco, que é uma variável aleatória com média zero e variância W .

$$X_{k+1} = a * X(a) + w(k) \quad (2)$$

Após a definição da equação linear, é realizado o cálculo da estimativa inicial X_i através da multiplicação da estimativa anterior X_e pela constante do sistema linear a . A primeira estimativa inicial é calculada através da EQUAÇÃO 3. Como não se conhece a estimativa anterior, ela é definida de forma aleatória e por isso não é possível definir a variância de seu erro.

$$X_i = a * X_e(0) \quad (3)$$

Na segunda etapa é calculada a variância do erro da estimativa inicial PP através da multiplicação dos valores da variância do erro da estimativa anterior P , da variância da perturbação do sistema (W) e novamente da constante do sistema

linear a , como mostra a EQUAÇÃO 4. Não é possível definir a variância do erro para a primeira estimativa inicial e por isso o valor dessa variância é definido de forma aleatória e com valor geralmente elevado.

$$PP = P * a^2 * W \quad (4)$$

Para as três últimas etapas, será inserido o ruído na medição de $x(k)$, que é o ruído na medida dos sensores que compõe o sistema, obtendo assim um novo sistema linear com uma nova equação. A medida é $y(k)$, a constante do sistema é M e o ruído é $u(k)$ de variância U . A equação do novo sistema será semelhante à apresentada pela EQUAÇÃO 5.

$$y(1) = M * x(1) + u(1) \quad (5)$$

Na terceira etapa utiliza-se a constante do novo sistema M , a variância calculada na segunda etapa PP e a variância do erro da medida do sensor U para calcular o ganho de Kalman K . O ganho de Kalman será utilizado para encontrar a nova estimativa $X_e(1)$ e a variância do erro da nova estimativa P que são as duas últimas etapas. A EQUAÇÃO 6 é utilizada para calcular o ganho de Kalman.

$$K = \frac{M * PP}{PP * M^2 * U} \quad (6)$$

Na quarta etapa é feita uma nova estimativa $X_e(1)$, que será a saída do filtro, ou seja, a estimativa que se deseja encontrar. O cálculo dessa nova estimativa é feito através dos valores da estimativa inicial X_i , do ganho de Kalman K , da medida ruidosa $y(1)$, que é o valor de entrada do filtro e para a aplicação do artigo serão as medidas de posição do veículo, e da constante do novo sistema M . A equação 7 é utilizada para calcular a nova estimativa.

$$X_e = X_p + K\{y(1) - M * x_p\} \quad (7)$$


Na quinta e última etapa, será calculada uma nova variância, agora para o erro da nova estimativa. Para esse cálculo será necessário o valor da variância do erro da estimativa inicial PP , da variância do erro da medida do sensor U , do ganho de Kalman K e do valor da constante do novo sistema M . A nova variância pode ser obtida através da equação 8.

$$P(1) = PP * (1 - K * M)^2 + (U * K^2) \quad (8)$$

O valor da variância do erro da nova estimativa será utilizado para o cálculo da próxima estimativa inicial, reiniciando assim a sequência do filtro de Kalman.

Uma navegação utilizando apenas o INS fornece posição precisa por curtos períodos de tempo, mas ao longo do tempo a solução gera ruídos devido ao acúmulo de erros dos giroscópios e acelerômetros. Esses erros poderiam ser corrigidos através de uma solução GNSS, porém isto se torna difícil mais se houver perda de sinal devido alguma obstrução do sinal dos satélites num longo período de tempo, como por exemplo, devido a obstrução do sinal GNSS causada por edifícios ou vegetação, como apresenta a FIGURA 2. Portanto, a integração dos dados numa solução única aplicando o filtro de Kalman fará com que a solução GNSS e INS tenha uma melhor convergência para o valor real. (KING, 1998)

FIGURA 2 - LASER TERRESTRE MÓVEL UTILIZANDO POSICIONAMENTO GNSS-INS PARA O GEORREFERENCIAMENTO DIRETO DE DADOS DE VARREDURA A LASER




FONTE: KUKKO (2013).

Todos os cuidados básicos de planejamento devem ser avaliados, como previsão do tempo no dia do levantamento, almanaque dos satélites para analisar a geometria, PDOP inferior a 5, condições atmosféricas favoráveis e a instalação de um receptor GNSS em solo, como base e com comprimento de linha máxima de até 15km.(NCHRP, 2013)

2.2.4 DMI

Quando há problemas de obstrução do sinal GNSS por um longo percurso, onde os dados do IMU também estão degradados, os dados referentes ao DMI são priorizados. O DMI é um dispositivo eletromecânico instalado nas rodas do veículo que o sistema móvel está instalado, conforme apresenta a FIGURA 3 (a). Ele mede a rotação da roda que indiretamente fornece a distância percorrida. Isso faz com que a informação fornecida pelo GNSS seja aumentada com a informação do DMI. A FIGURA 3 (a) apresenta o detalhe do dispositivo e a FIGURA 3 (b) o dispositivo instalado.

FIGURA 3 - DMI. (A) DETALHE DO SISTEMA DMI. (B) SISTEMA DMI INSTALADO NA RODA DE UM CARRO (CORTESIA DE ESTEIO).



FONTE: A autora (2016)

Seus pulsos de saída representam revoluções e são convertidos em distância, fornecendo uma medida da distância percorrida pelo veículo. O fator de escala DMI pode ser calculado pelas duas fórmulas seguintes:

(1) DMI (Tipo 1):

$$S = \frac{n}{d\pi} \quad (9)$$

(2) DMI (Tipo 2):

$$S = \frac{4n}{d\pi} \quad (10)$$

onde:

n = número de pulsos por revolução DMI

d = diâmetro da roda

As derivas na trajetória causadas pelas paradas e falta de informação GNSS são ajustadas por Filtro de Kalman. Ele compara a solução do inercial com os dados GNSS correspondentes e faz um ajuste.

2.2.5 Câmeras Digitais

Os dados coletados pelo *LASER scanner* são geralmente convertidos em coordenadas tridimensionais e uma medida de intensidade, porém esta informação espectral não é suficiente para caracterizar uma feição. Por isso, câmeras digitais foram incorporadas nos sistemas para auxiliar a visualização fazendo a correlação das imagens com os dados tridimensionais, bem como, colorir cada ponto coletado com a informação (RGB) do valor de vermelho, verde, azul que descreve a cor no mundo real. A riqueza visual que uma imagem pode fornecer a nuvem de pontos não é a mais relevante, mas atualmente a informação de cor como atributo do ponto esta sendo utilizada em técnicas de extração automática.

Os sistemas diferem bastante quanto a quantidade de câmeras utilizadas e a disposição que elas são instaladas no equipamento. São instaladas estrategicamente para garantir a cobertura de 360 graus na horizontal e realizar análises qualitativas e quantitativas dos dados coletados, conforme apresentado na FIGURA 4.

FIGURA 4 - CAMERAS INSTALADAS NO SISTEMA LASER MOVEI



FONTE: A autora (2016).

2.2.6 Principais sistemas existentes no mercado

Existem vários sistemas móveis terrestres comerciais que foram desenvolvidos e inseridos no mercado devido ao avanço da tecnologia laser scanner nesses últimos anos. O QUADRO 1 apresenta os principais sistemas comerciais disponíveis no mercado com suas respectivas configurações e a FIGURA 5 apresenta oito tipos de sistemas de mapeamento móvel instalados nos veículos.

QUADRO 1 - SISTEMAS MLS DISPONÍVEIS COMERCIALMENTE

Company		RIEGL	RIEGL	Trimble	Optech	TOPCON	3D laser mapping Ltd.& IGI mbH	Dynascan	SITECO
MLS system		VMX-250	VMX-450	MX8	Lynx –M1	IP-S2 Compact+	StreetMapper	S250	ROAD SCANNER
Laser Scanner	Laser Type	RIEGL VQ-250 (2)	RIEGL VQ-450 (2)	RIEGL VQ-250 (2)	Lynx laser scanner (2)	SICK LMS 291(5)	VQ180 or VQ250	MDL scanner	Faro Focus 3D (3)
	Measuring Principle	Time-of-flight measurement; Echo signal digitalization; Online waveform processing;			Time-of-flight		Time-of-flight measurement; Echo signal digitalization; Online waveform processing;	Time-of-flight	Phase difference
	Maximum range	500 m (to 80% reflectivity target)	800 m (to 80% reflectivity target)	500 m (to 80% reflectivity target)	200 m (to 20% reflectivity target)	80 m (to 10% reflectivity target)	500 m (to 80% reflectivity target)	250 m	120 m (to 90% reflectivity target)
	Minimum range	1.5 m	1.5 m	1.5 m		0.7 m	1.5 m		
	Measure precision	5 mm (1 sigma)	5 mm (1 sigma)	5 mm (1 sigma)	8 mm (1 sigma)	10 mm at range of 1 to 10	5 mm (1 sigma)	±1 cm (1 sigma)	1 mm (at 25 m)
	Absolute accuracy	10 mm	8 mm	10 mm	5 cm (at 100 km/h at good GPS data)	± 35 mm	10 mm	± 5 mm	±2 mm (at 25 m)
	Field of view	360°	360°	360°	360°	180°/90°	360°	360°	H360° V320°
	Scan rate	Up to 100 Hz	Up to 200 Hz	80-200 Hz	100 Hz	75-100 Hz	100 Hz	Up to 30 Hz	48 Hz
	Measurement rate / pulse repetition rate (PRR)	50-300 KHz	Up to 550 KHz	50-300 KHz	75-500 KHz	40 KHz	50-300 KHz	36 KHz	122-976 kHz
	Echoes per pulse	Practically unlimited			Up to 4 echoes		Practically unlimited		
	Angle measurement resolution	0.001°	0.001°	0.001°	0.001°	0.667°	0.001°	0.01°	H0.00076° V0.009°
Laser wavelength		near infrared			1550 nm (near infrared)	905 nm (near infrared)	Near infrared		785 nm (near infrared)
Navigation solution		LV-510	LV-510	LV-510	LV-410	40 channels, dual constellation, dual frequency GPS + GLONASS L1/L2; Fiber Optic Gyro	IGI's TERRAcontrol : NovAtel GNSS receiver +IGI's IMU-IIId fiber optic gyro IMU	Dual GNSS	LANDINGS navigation system & IXSEA inertial system
	Roll/Pitch	< 5 cm	< 5 cm	< 5 cm	± 5 cm (@ 30 m)	0.5 m -2 m	5 cm	2 cm	7 cm
	Heading	< 5 cm	< 5 cm	< 5 cm			5 cm		5 cm
Camera subsystem		500 MP (4 or 6)	500 MP (4 or 6)	Point Gray Grasshopper® GRAS - 50SSC (4)	200 / 500 MP (2)	Sony progressive scan color CCDs (6)	12 MP SLR (single-lens reflex)		BASLER Scout cameras (8)
	Lens Size	2/3" CCD	2/3" CCD	2/3" CCD	1/1.8" or 2/3" CCD	1/3" CCD			
	Lens types	5 mm	5 mm	4 mm	F 1.8/ 4.8 mm	2.5 mm			
	Field of view	80°× 65°	80°× 65°		57°× 47°	>80% of full sphere, 360° Panorama			
	Exposure (#/s)	8	8	4	3	15	2		Max. 30
Reference		(RIEGL VMX-250, 2013)	(RIEGL VMX-450, 2013)	(Trimble MX-8, 2013)	(Optech Lynx –M1, 2013)	(Topcon IP-S2, 2013)	(StreetMapper, 2013)	(Dynascan S250, 2013)	(Road Scanner, 2013)

FONTE: Adaptado apresentação Leica Geosystem 2014.

FIGURA 5 - (A) RIEGL VMX-450, (B) TRIMBLE MX 8, (C) OPTECH LYNX, (D) TOPCON IP-S2 COMPACT+, (E) STREETMAPPER, (F) DYNASCAN S250, (G) LEICA PEGASUS: ONE (LEICA PEGASUS: ONE, 2013), AND (H) ROAD SCANNER.



(a) Riegl MX-450



(b) MX-8



(c) Lynx



(d) IP-S2



(e) Street Mapper



(f) Dynascan S250



(g) Leica Pegasus:One



(h) Road Scanner

FONTE: Adaptado GUAN, 2013

Conforme GUAN (2013), o equipamento FARO PHOTON 120 no sistema Road Scanner é o mais preciso porque utiliza a tecnologia de mudança de fase ou *phase shift*, enquanto o SICK e o MDL são os menos precisos. No entanto, devido à tecnologia *time-of-flight*, os equipamentos RIEGL, MDL e LYNX tem alcance maior que 200 m e o RIEGL VQ-450 acima de 800 m.

Quanto ao ângulo de varredura, os scanners VQ-250 450, MDL e LYNX são capazes de cobertura 360 graus, enquanto o FARO e SICK não. O LYNX é o sistema mais popular internacionalmente.

Topcon e MDL são muito compactos e bem integrados sem unidade de controle extra, são facilmente transportáveis de uma plataforma para outra. RIEGL, StreetMapper e Optech possuem uma pequena unidade de controle, que normalmente fica na parte traseira do veículo, mas também é removível, no entanto SITECO e Trimble são os sistemas menos portáteis por causa do tamanho e peso de suas unidades de controle.

Todos os sistemas produzem uma nuvem de pontos muito densa com uma enorme quantidade de dados em curtas distâncias, alguns sistemas possuem dois ou três scanners, logo, independente do sistema o resultado será uma nuvem de pontos com alto grau de detalhamento. A velocidade do veículo é o principal fator que determina a densidade de pontos durante o levantamento. Com o ajuste da velocidade do veículo e o ângulo de varredura é possível determinar a resolução desejada. A densidade de pontos é importante para vários tipos de aplicações rodoviárias, incluindo manutenção de estradas, de encostas, pontes, drenagem, alta tensão e vegetação.

2.2.7 Aplicações do MTLs

Os dados captados pelo MTLs podem ser georreferenciados em qualquer sistema de coordenadas e podem ser usados em diferentes tipos de mapeamento, como levantamentos viários, ferroviários e hidrográficos. A instalação do sistema pode ser realizada em diferentes plataformas, desde carros, vans até em barcos. A FIGURA 6 apresenta exemplos de diferentes tipos de aplicações e seus respectivos resultados. (SHERIF, 2013).

A varredura laser móvel é adequada para medir a geometria da estrada, pavimentos, meio-fio, pinturas de faixas e objetos ao lado da estrada que são medidos simultaneamente.


FIGURA 6 - EXEMPLOS DE SISTEMAS INSTALADOS EM DIFERENTES PLATAFORMAS COM SUAS RESPECTIVAS APLICAÇÕES



a) Instalação em automóvel para levantamentos viários.



b) Instalação em equipamento para levantamentos ferroviários.



c) Instalação em barco para levantamentos hidrográficos.

FONTE: Adaptado Leica, 2013

2.3 SISTEMA TERRESTRE MÓVEL PEGASUS ONE

Os dados utilizados neste estudo foram capturados pelo sistema móvel Pegasus One. O sistema suíço foi lançado na feira Hexagon Live 2013 nos Estados Unidos e pertence a empresa Leica Geosystem. Chegou ao Brasil apenas em 2014. Ele é praticamente como todos os sistemas móveis, composto por sensor LIDAR, um receptor GNSS, um IMU, um DMI e o diferencial entre os outros sistemas são as seis (6) câmeras digitais métricas, instaladas na frente, atrás e nas laterais da plataforma do veículo. Os componentes estão apresentados detalhadamente na (FIGURA 7).

FIGURA 7 - COMPONENTES DO SISTEMA PEGASUS ONE




FONTE: Adaptado Pegasus Roadway Presentation (2015)

O sistema inicialmente gera uma trajetória através das informações da solução GNSS e IMU, em conjunto, uma varredura sem registro e as fotos são sincronizadas, conforme apresentado na (FIGURA 8). Essa sincronização é

realizada a partir de algoritmos proprietários e suas respectivas otimizações são realizadas, em algumas vezes, automaticamente sem parametrização. Após um processamento, o resultado do levantamento é um arquivo de pontos devidamente orientado num sistema de projeção e imagens orientadas conforme a nuvem de pontos.

FIGURA 8 - FUNCIONAMENTO DE UM MAPEAMENTO MÓVEL



FONTE: Adaptado apresentação Leica Geosystem 2014.

O Pegasus One apresenta a vantagem em ser *plug and play*, ou seja, sua instalação é rápida e combinada com um software de fácil operabilidade, apresentado na FIGURA 9, evitando assim a necessidade de um treinamento exaustivo antes de um levantamento.

FIGURA 9 - INSTALAÇÃO DO SISTEMA E VEÍCULO COM O SISTEMA INSTALADO.



FONTE: A autora (2016).

2.4 GEORREFERENCIAMENTO E EQUAÇÃO DE POSICIONAMENTO DO MTLS

O LASER *scanner* está referenciado quando a sua posição e orientação em relação ao sistema de coordenadas de mapeamento é conhecido por um conjunto de sistemas de navegação. Para uma perfeita integração de sensores e determinação exata das coordenadas dos pontos mapeados, os dados de navegação precisam obter um tempo GNSS muito preciso. (BARBER ET AL, 2008)

A (FIGURA 10) apresenta o georreferenciamento entre sensores num sistema MTLS com suas respectivas equações. As indicações de 1 a 7 representam cada parte da equação em função dos sensores que fazem parte do sistema. As coordenadas do ponto P, apresentado na (FIGURA 15) podem ser calculadas por:

$$\begin{array}{ccccccc}
 \textcircled{1} & \textcircled{2} & \textcircled{3} & \textcircled{4} & \textcircled{5} & \textcircled{6} & \textcircled{7} \\
 \begin{bmatrix} X_p \\ Y_p \\ Z_p \end{bmatrix}^M & = & \begin{bmatrix} X_{GPS} \\ Y_{GPS} \\ Z_{GPS} \end{bmatrix}^M & + & R_{IMU}^M(\omega, \varphi, K) * & \left(R_S^{IMU} * (\Delta\omega, \Delta\varphi, \Delta K) * r_p^S(\alpha d) + \begin{bmatrix} L_X \\ L_Y \\ L_Z \end{bmatrix}^{IMU} - \begin{bmatrix} L_X^{G11} \\ L_Y^{G11} \\ L_Z^{G11} \end{bmatrix}_{IMU}^{GPS} \right) \\
 & & & & & & (11)
 \end{array}$$

onde:

X_p, Y_p, Z_p = Localização do alvo P no terreno

$X_{GPS}, Y_{GPS}, Z_{GPS}$ = Localização da antena GNSS no terreno

$r_p^S(\alpha d)$ = Posição relativa do ponto P no sistema de coordenadas do laser scanner, P e d para as medidas de ângulos e range.


L_X, L_Y, L_Z = Lever arm offset a partir da origem do IMU até o sensor laser. Esses valores devem ser determinados por uma calibração do sistema ou medidas manuais.

$L_X^{G11}, L_Y^{G11}, L_Z^{G11}$ = Lever arm offset do IMU até a origem GNSS. Esses valores devem ser determinados por uma calibração do sistema ou medidas manuais.

$R_{IMU}^M(\omega, \varphi, K)$ = Matriz de rotação IMU e terreno, (ω, φ, K) representam o roll, pitch e yaw do sensor referenciado ao terreno. Esses valores são dados pelo IMU.

$R_S^{IMU}(\Delta\omega, \Delta\varphi, \Delta K)$ = Matriz de rotação do laser scanner e o terreno, $(\Delta\omega, \Delta\varphi, \Delta K)$ são os ângulos de alinhamento do scanner com o IMU. Esses valores são determinados por uma calibração.

FIGURA 10 - GEORREFERENCIAMENTO ENTRE OS SENSORES EM UM SISTEMA MTLs



FONTE: Adaptado GUAN 2013

Como o estudo será realizado utilizando a nuvem de pontos, será necessário apresentar alguns parâmetros. As grandezas de velocidade de escaneamento, espaçamento entre linhas, espaçamento entre pontos e densidade de pontos podem ser calculadas respectivamente por:

$$S_s[\text{lines/s}] = \frac{L_{inc}[\text{deg}] * PRR[\text{Hz}]}{360^\circ} \quad (12)$$

$$L_{dist}[\text{m/line}] = \frac{S_G[\text{m/s}]}{S_s[\text{lines/s}]} \quad (13)$$

$$P_{dist}[\text{m}] = \tan (L_{inc}[\text{deg}] * T_{dist}[\text{m}]) \quad (14)$$

$$P_{density}[\text{pts/m}^2] = \frac{1}{P_{dist}[\text{m}] * L_{dist}[\text{m}]} \quad (15)$$

Onde:

S_s	velocidade de escaneamento
S_G	velocidade do veículo
L_{dist}	espaçamento entre linhas
P_{dist}	espaçamento entre pontos
T_{dist}	distância do alvo
L_{inc}	Incremento da linha
$P_{density}$	densidade média de pontos

A densidade média dos dados coletados depende da velocidade de varredura S_s , velocidade do veículo S_G e taxa de repetição do pulso medido pelo sistema (PRR - *Pulse Repetition Rate*). A velocidade de varredura é determinada pelo PRR e pelo incremento da linha L_{inc} . O espaçamento da linha de varredura P_{dist} é proporcional a S_G e inversamente proporcional a S_s , indicando que quanto

maior a velocidade do veículo, menor será o espaçamento da linha de varredura na direção da varredura, enquanto maior a velocidade de varredura, maior será o espaçamento entre as linhas da varredura.

2.5 PRECISÃO E FONTE DE ERROS

A maioria dos instrumentos de medição possui erros sistemáticos, randômicos, temporais ou estáticos e os sistemas de mapeamento não são exceções. Conforme GUAN (2013) as principais fontes de erros são:

- IMU: O IMU consiste de 3 acelerômetros que medem a aceleração ao longo de um eixo específico e 3 giroscópicos que medem e mantêm a orientação, baseado nos princípios do momento angular. Os erros sistemáticos são tendência no acelerômetro e deriva no giroscópio. Como os componentes de um IMU são fornecidos por fabricantes diferentes, cada um possui uma precisão diferente. A Tabela 1 apresenta o desempenho IMU de marca SPAN IMU-FSAS, utilizado no Pegasus One, com interrupções de 0, 10 e 60 segundos e com os modos de posicionamento RTK (*Real Time Kinematic*), SP (*Static Position*) e PPP (*Precise Point Positioning*) suas respectivas precisões.


TABELA 1 - DESEMPENHO DO IMU DURANTE A INTERRUPÇÃO DO GNSS

Duração da interrupção	Modo de posicionamento	Precisão de posição (m) RMS		Precisão de velocidade (ms) RMS		Precisão de atitude (graus) RMS		
		H	V	H	V	Roll	Pitch	Heading
0s	RTK	0.02	0.05	0.020	0.010	0.008	0.008	0.023
	SP	1.20	0.60	0.020	0.010	0.009	0.013	0.024
	PPP	0.01	0.02	0.020	0.010	0.004	0.004	0.013
10s	RTK	0.13	0.06	0.026	0.010	0.010	0.010	0.025
	SP	1.34	0.67	0.035	0.014	0.014	0.014	0.026
	PPP	0.01	0.02	0.020	0.004	0.004	0.004	0.013
60s	RTK	3.50	0.32	0.135	0.015	0.015	0.015	0.040
	SP	4.44	0.87	0.151	0.018	0.018	0.018	0.040
	PPP	0.15	0.04	0.023	0.005	0.005	0.005	0.014

FONTE: GUAN (2013).

- GNSS: Os erros provenientes da precisão do GNSS podem ser influenciados por vários fatores: multicaminhamento, erros atmosféricos, linha de base, geometria inadequada e perda de sinal. A precisão ideal esperada é 1 cm + 1 ppm na horizontal e 2 cm +1 ppm na vertical com uma base de raio inferior a 30km.
- Laser scanner: O sensor laser pode gerar um erro na distância ocasionado pela precisão interna do relógio que mede o tempo de ida e volta do pulso laser, erro angular devido a resolução do codificador do laser scanner e da incerteza da divergência do feixe. O scanner do sistema Pegasus ONE é o Profiler 9012 da Z+F que possui divergência do feixe <3mrad e erro linear <1mm.
- *Boresight*: Esse erro é o desalinhamento entre eixos IMU e o sensor laser. O *boresighting* é um processamento de medida muito preciso que tem como objetivo corrigir qualquer desalinhamento na montagem entre IMU e sensor.
- *Lever arm*: Para se obter uma nuvem de pontos com precisão é necessário conhecer os offsets do *lever arm*, ou seja, as distâncias lineares que os sensores estão entre si. Essa medição deve ser realizada ou por calibração de fábrica ou medidas físicas. A FIGURA 11 apresenta os sensores e o lever arm entre eles.

FIGURA 11 - LEVER ARM OFFSETS EM UM SISTEMA MTLS



FONTE: Adaptado GUAN 2013

Existem vários fatores que podem se tornar fontes de erros em um sistema MTLS, além dos erros oriundos do sistema, existem os erros de processamento e erros de captura. O pós-processamento da trajetória é essencial para se obter um posicionamento preciso da nuvem de pontos e alguma parametrização incorreta pode comprometer o levantamento. Elementos com muita reflectância também podem causar erros, bem como, levantamentos realizados em velocidade inadequada ou em áreas urbanas muito verticais.

2.6 COMPARAÇÃO DO SISTEMA TERRESTRE MÓVEL COM O SISTEMA AÉREO.

Os sistemas aéreo e terrestre compartilham de similaridades e diferenças, quando comparados entre eles. Os itens 2.6.1 e 2.6.2 apresentam os principais.

2.6.1 Principais similaridades

- Ambos os sistemas possuem o modo cinemático de captura de dados quanto ao sistema de posicionamento obtido pela combinação de GNSS e IMU.

- A nuvem de pontos é gerada por ambos os sistemas com o retorno de intensidade.
- Cada ponto é georreferenciado individualmente;

2.6.2 Principais diferenças

- O laser aéreo possui um *footprint* muito maior que o laser terrestre e sua nuvem de pontos tende ser mais uniforme que o laser terrestre.
- Pontes e tuneis podem ser coletados com o laser terrestre ao contrário do laser aéreo. A coleta de dados possui mais flexibilidade com o laser terrestre por acessar ângulos que com o laser aéreo não é possível.
- O laser terrestre é limitado para pequenas áreas, normalmente detalhes ou corredores, enquanto o aéreo não.
- O custo de levantamento com o laser aéreo é muito maior que com o laser terrestre.
- A precisão do laser terrestre é maior que o laser aéreo.

Uma consideração importante é que apesar do MTLIS se apresentar como uma ferramenta importante e promissora na área rodoviária, no Brasil, ainda não possui nenhuma padronização. Neste sentido, dá-se a necessidade de documentação adequada dos projetos existentes, bem como, o fomento de novas pesquisas sobre essa tecnologia.

2.7 MOBILIÁRIO URBANO

Conforme a legislação brasileira, lei 10.098/2000, o termo mobiliário urbano é definido como “conjunto de objetos presentes nas vias e espaços públicos, superpostos ou adicionados aos elementos da urbanização ou da edificação” (BRASIL, 2000). De acordo com essa norma, são exemplos de mobiliário urbano: semáforos, paradas de ônibus, postes de sinalização e de iluminação, cabines telefônicas, placas, lixeiras e bancos.


Considerando os aspectos estéticos e de uso, o mobiliário urbano corresponde às seguintes categorias: circulação e transporte (abrigos de ônibus, acessos ao metrô, semáforos e placas de sinalização), infraestrutura (cabines e telefones públicos, luminárias, postes de luz e lixeiras) e ornamentação da paisagem e ambientação urbana (bancos e assentos). (ABNT, 1986).

A relação entre o mobiliário urbano e as edificações de entorno deve ser considerada para o êxito de projetos de implantação desses elementos no espaço público. A falta de correspondência entre o mobiliário e as edificações do meio pode interferir negativamente na leitura visual do espaço, conforme indicam resultados de avaliação estética realizada com mobiliário urbano inserido em locais onde há edificações detentoras de reconhecido valor histórico e arquitetônico (JOHN, REIS, 2010).

Este projeto utilizará apenas os elementos do mobiliário urbano, instalados no campus do Centro Politécnico da UFPR (Universidade Federal do Paraná), do tipo postes de iluminação e placas de sinalização e suas respectivas classificações. Os postes de iluminação estão distribuídos no campus com a finalidade de iluminar o ambiente de maneira suficiente e segura. As placas de sinalização mantêm a comunicação visual e desempenha um papel importante em chamar a atenção de uma forma rápida, clara e informativa.

Atualmente estão instalados 2 tipos de postes de iluminação interna. O primeiro com aproximadamente 12 metros de altura, 4 lâmpadas de vapor de sódio de 400 Watts de potência em cada poste, totalizando 1600 Watts em cada poste. E o segundo contendo apenas 1 lâmpada de sódio de alta pressão com 70 Watts de potência, com um globo de policarbonato transparente. A luminária é feita com aletas refletoras feitas em chapas de alumínio. A FIGURA 12 apresenta os tipos de postes com o detalhe e dimensões das lâmpadas.

FIGURA 12 - TIPOS E DIMENSÕES DOS POSTES DA UFPR



Poste de iluminação com 4 lâmpadas



Poste de iluminação com 1 lâmpada transparente

FONTE: Adaptação (2016)

A sinalização vertical tem o objetivo de informar ao usuário qual o comportamento a ser adotado visando a segurança e melhor fluxo de tráfego. Podem ser classificadas em regulamentação, advertência e indicação. Todos os símbolos e legendas devem obedecer a diagramação do Manual Brasileiro de Trânsito.

As placas possuem uma padronização quanto ao material fabricado, cor, altura, postes e pintura. Devem ser retrorrefletivas, luminosas ou iluminadas para garantir a visibilidade. E independente do período diurno ou noturno, devem apresentar as mesmas cores.

A FIGURA 13 apresenta exemplos de placas de regulamentação, advertência e indicação utilizadas nesse estudo.

FIGURA 13 - TIPOS DE PLACAS DE SINALIZAÇÃO

Placa de regulamentação R-1
Parada obrigatóriaPlaca de advertência A-32a
Trânsito de pedestresPlaca indicativa
Placas para condutores

FONTE: Adaptação (2016)


2.8 DETECÇÃO DE POSTES E PLACAS.

A investigação na detecção automática de diferentes elementos que estão próximos das vias tem como objetivo reduzir o tempo e o custo de um levantamento manual e individualizado. Algumas pesquisas já foram realizadas quanto à detecção de feições a partir da nuvem de pontos do MTLs, este capítulo apresentará um resumo das principais abordagens.

Manadhar e Shibasaki (2001) fizeram as primeiras tentativas de medir os elementos da superfície de uma estrada com MTLs. O sistema que desenvolveram era composto por seis câmeras de linha, três scanners a laser e *Hybrid Inertial Survey System* (HISS), que consiste em DGPS, INS e um odômetro eletrônico para

dados de posição e orientação, apresentado na FIGURA 14. A frequência de varredura a laser era de 20Hz, o que permitia dirigir a uma velocidade de 40km / h. O período de aquisição contínua de dados foi aumentado uma quantidade ilimitada de distância de levantamento ou enquanto os erros INS/GPS estivessem dentro do limite permitido o melhoramento do mecanismo de gravação de dados de cada um dos sensores para o disco.

FIGURA 14 - SISTEMA MTLs DE 2001.



FONTE: Manadhar e Shibasaki (2001)

Um dos objetivos da pesquisa de Manadhar e Shibasaki (2001) era a extração de dados a partir da nuvem de pontos 3D, sem nenhuma informação extra como o valor da reflectância, ou seja, a intensidade. Basicamente os objetos foram classificados em duas classes: a artificial e a natural. Os elementos que pertenciam à classe natural eram árvores e mato e à classe artificial eram os edifícios, estradas, instalações de utilidade pública como postes e placas, pavimento, guard-rails e outros. O objetivo principal era a extração de fachadas das construções, árvores e estradas. Também estavam interessados em extrair objetos em movimento e não em movimento, como veículos estacionados, veículos em movimento, pedestres e assim por diante.

O pré-processamento dos dados foi realizado separando as feições artificiais das naturais. As feições naturais possuem a característica dos pontos serem espalhados devido à sua forma geométrica irregular, onde como pontos de feições artificiais geralmente não são dispersos devido a sua forma geométrica. A fim de analisar a dispersão dos pontos em três dimensões, foi utilizada a análise da segunda derivada da distância, conforme apresentado na FIGURA 15. O estudo comprova que a variação da distância é maior nas feições naturais, como árvores, e menor nas feições artificiais como edifícios, paredes e estradas.

FIGURA 15 - ANÁLISE DA SEGUNDA DERIVADA DA DISTÂNCIA DE UMA LINHA LASER



FONTE: Manadhar e Shibasaki (2001)

Chen et al (2007), utilizaram um sistema composto por três tipos de sensores, laser, cameras CCD e uma plataforma de navegação GPS/IMU/VMS fixa. O equipamento laser utilizado foi o LMS 200, que é um laser bidimensional, com alcance máximo de 80 metros e uma resolução média de 30 mm. A frequência de varredura utilizada foi de 37,5Hz e aproximadamente 27 linhas de escaneamento por segundo. A plataforma de navegação utilizada é composta por um DGPS, um IMU e um VMS (Velocity measurement system), conforme apresenta a FIGURA 16 com o sistema completo montado em cima do veículo.

Para a medição de dados, todos os sensores mantêm registros de dados à medida que o veículo avança. Quando o veículo avança a uma velocidade normal, os scanners a laser perfilam a seção transversal, as câmeras CCD capturam a cena ao longo da estrada. Enquanto isso, a unidade de navegação coleta dados de navegação, incluindo a posição precisa, a postura e a velocidade do veículo. Todas as unidades estão sob o controle dos computadores e sincronizados pelo pulso de disparo do GPS.

FIGURA 16 - SISTEMA CHEN ET AL (2007), MONTADO SOBRE A PLATAFORMA FIXA.




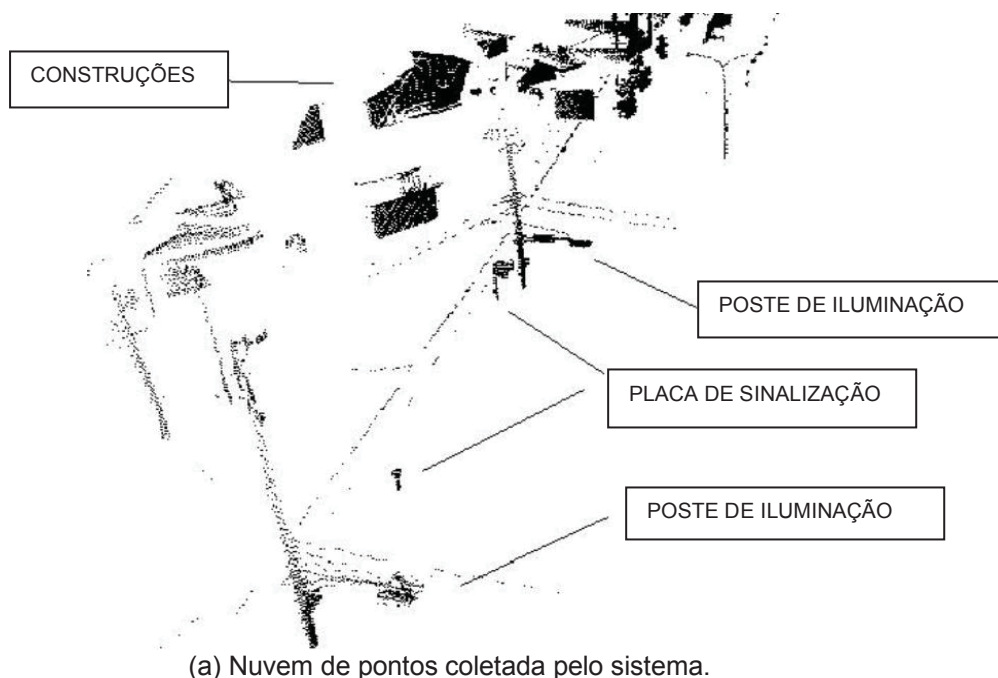
FONTE: Chen et al (2007)


Neste estudo, os objetos urbanos de interesse foram principalmente postes e sinais de trânsito. A FIGURA 17 (a) mostra vários elementos registrados na nuvem de pontos adquirida pelo LASER scanner. Sabe-se que os postes e sinais de trânsito estão sempre localizados perto do limite da estrada na área urbana ou semi-urbana. Se a posição do limite da estrada é conhecida antecipadamente, a maioria dos pontos de laser não pertencentes a faixa de interesse podem ser removidos sem segmentação.

O perfil com os pontos laser é obtido pelo sensor instalado na parte traseira do veículo, que faz o escaneamento da estrada com um pequeno ângulo de inclinação. Nesse sistema as bordas da estrada são detectadas através de perfis transversais, conforme apresentado FIGURA 17 (b). As quebras ocorrem quando o laser encontra o meio-fio e nos casos onde não existe, é necessário extrair manualmente.

A FIGURA 17 (c) apresenta a nuvem de pontos depois que os pontos redundantes foram excluídos. A partir dessa nuvem de pontos, foi utilizado um algoritmo de clustering baseado na distância entre pontos para separar todos os pontos em diferentes elementos. A segmentação dos objetos foi o próximo passo, onde foi considerada a característica linear dos postes para a extração do objeto. Todos os objetos foram projetados num plano horizontal 2D e cada objeto foi composto por um grupo de pontos 2D. A partir das componentes principais, os elementos candidatos a postes ou placas foram selecionados.

FIGURA 17 - DADOS E RESULTADOS DO SISTEMA CHEN ET AL (2007),







(c) Resultado após a filtragem.

FONTE: Chen et al (2007)

Golovinski et. al. (2009) realizaram um projeto para reconhecer objetos de ambientes urbanos, a partir de uma nuvem de pontos 3D da cidade de Ottawa. O projeto foi desmembrado em quatro etapas: localização, segmentação, caracterização e classificação de aglomerados de pontos 3D, conforme apresentado na FIGURA 18. Primeiramente os pontos próximos são agrupados para formar um conjunto de locais com potencial chance de ser um objeto, um agrupamento hierárquico. Então os pontos foram segmentados em primeiro e segundo plano e posteriormente, foi gerado um vetor para cada grupo de pontos, conforme FIGURA 19, o gráfico de vizinhos mais próximos é mostrado à esquerda, com nós na cor preta no primeiro plano, bordas em azul e bordas no corte em vermelho. O objeto extraído é mostrado à direita. Finalmente, os vetores foram rotulados usando um classificador treinado em um conjunto de objetos rotulados manualmente.

FIGURA 18 - ETAPAS DO PROCESSAMENTO DA METODOLOGIA DE GOLOVINSKI.






d) Extração

e) Classificação

FONTE: Golovinski et. al. (2009)

Eles testaram e compararam vários métodos em cada etapa. A aplicação de múltiplos métodos de segmentação fornece resultados diferentes e, portanto, uma maior variedade de características pode ser utilizada na etapa de classificação. Os segmentos são classificados aplicando o vizinho mais próximo, *Randon Forest* e algoritmos SVM (*Support Vector Machine*). O sistema de desenvolvimento detectou 65% dos objetos de referência.


FIGURA 19 - EXEMPLO DE SEGMENTAÇÃO DE UMA FEIÇÃO.



FONTE: Golovinski et. al. (2009)

O processamento e manipulação da nuvem de pontos de um MTLS é uma tarefa desafiadora devido à enorme quantidade de dados para processar. Por isso, Pu et al (2011) propõem separar a nuvem de pontos em blocos, segundo trajetória percorrida pelo automóvel, como está apresentado na FIGURA 20.

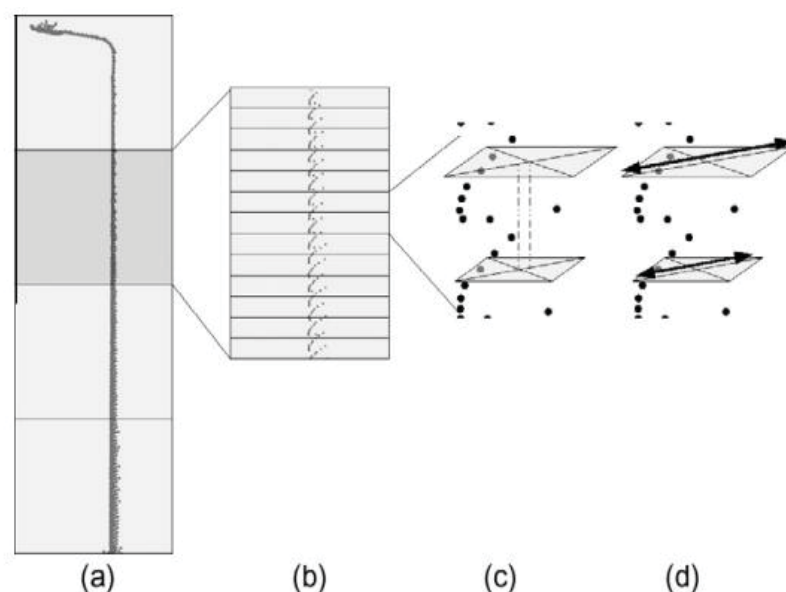
FIGURA 20 - SEPARAÇÃO DA NUVEM DE PONTOS EM BLOCOS.



FONTE: Pu et al (2011)

Após essa etapa, separou-se novamente a nuvem em três classes: superfície de terreno, objetos no terreno e objetos não-terreno. A partir dessa separação, utilizando a classe objetos no terreno, identificaram-se os postes analisando a variação do centro do elemento ao longo da vertical, conforme a FIGURA 21. O processo pode ser descrito como composto pelas seguintes etapas: a) verificação se existe um elemento vertical, b) caso positivo, separar o elemento em partes ao longo da vertical, c) verificar os desvios entre os centros das partes, d) calcular a extensão diagonal e o máximo da extensão.

FIGURA 21 - ALGORITMO BASEADO EM PORCENTAGEM



FONTE: PU ET AL. (2011)


Li et al (2013) apresentou um algoritmo automatizado para detectar coberturas de esgoto e bocas de lobo a partir de uma nuvem de pontos LIDAR MTLS utilizando técnicas desenvolvidas pelos outros autores citados anteriormente nessa dissertação, agregadas com a informação de intensidade do sinal. O algoritmo estocástico orientado a objetos baseia-se no paradigma Bayesiano, que pode processar de forma eficiente grandes volumes de nuvens pontuais em 3D, que cobrem superfícies rodoviárias com um número e tamanhos desconhecidos, como tampas de poços e bocas de lobo com baixa complexidade de tempo.

A ideia por trás desse processo "ponto marcado" foi modelar o número e a localização das tampas de poços de esgoto e bocas de lobo como o processo "ponto" e a definição de suas geometrias como "marcas". As nuvens de pontos da superfície da estrada são primeiramente rasterizadas em uma imagem de intensidade georeferenciada com base nas intensidades dos pontos de dados. Em seguida, as coberturas dos poços de esgoto e bocas de lobo de esgoto são automaticamente detectadas.

Ao invés de processar a nuvens de pontos da superfície da estrada em um espaço tridimensional, os pontos foram representados em uma imagem de intensidade bidimensional georreferenciada, na qual o valor digital de um pixel é interpolado de um grupo de pontos com base em suas intensidades. Para este fim, inicialmente os pontos foram projetados num plano x y, conforme apresenta a

FIGURA 22. O parâmetro r_g é o tamanho do grid ou a resolução da imagem de intensidade georreferenciada.

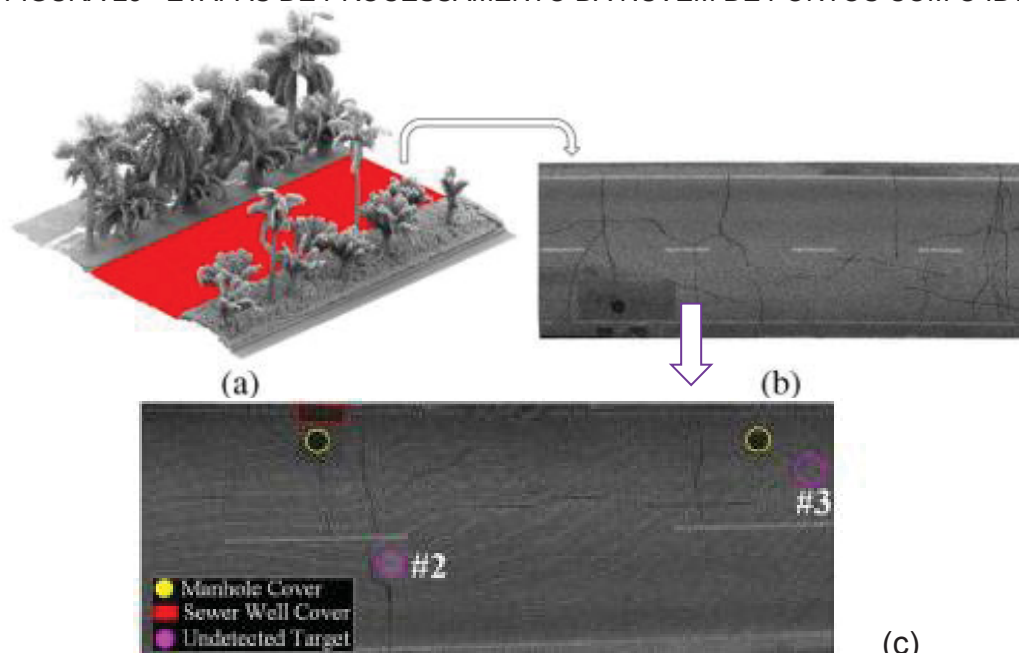
FIGURA 22 - MODELO DE GRID DE UMA NUVEM DE PONTOS E DETALHE DO PIXEL



FONTE: LI et al. (2011)

Para gerar a imagem de intensidade foi utilizado o método de interpolação IDW (*Inverse Distance Weighted*) com regras. O resultado está apresentado na FIGURA 23, onde é apresentada a nuvem de pontos com a estrada segmentada na cor vermelha (a), a imagem de intensidade gerada a partir da nuvem de pontos (b) e a nuvem de pontos com as indicações da localização das tampas dos poços de esgoto, das bocas de lobo e dos elementos não detectados.

FIGURA 23 - ETAPAS DE PROCESSAMENTO DA NUVEM DE PONTOS COM O IDW.



FONTE: LI et al. (2011)

Yang et al (2016) propôs um método inovador para a extração de elementos da faixa de domínio de uma estrada, como meio feio, pinturas de faixas, guardrails, edificações, postes de iluminação, sinaleiros, árvores, linhas de alta tensão e veículos para a construção de mapas com alta precisão chamados de HADMs (*High Accuracy Driving Maps*). Esses mapas são utilizados como base para os sistemas inteligentes criados em alguns automóveis para auxiliar a direção, chamados de ADASs (Advanced Driver Assistance Systems). Esses sistemas fornecem ao motorista a vantagem da interpretação da cena com um fundo adequado, modificar as informações faltantes causadas por oclusão, fornecer informações além do horizonte dos sensores e ajudar a posicionar os veículos.

Para o experimento foi utilizado o sistema MLS da Riegl que possui dois equipamentos laser VMX-450 instalados sob plataforma fixa. A FIGURA 24 apresenta um detalhe da nuvem de pontos, dos seis quilômetros de extensão de levantamento e o equipamento montado em cima do automóvel.

FIGURA 24 - DETALHE DA NUVEM DE PONTOS E SISTEMA RIEGL MONTADO NO VEÍCULO.

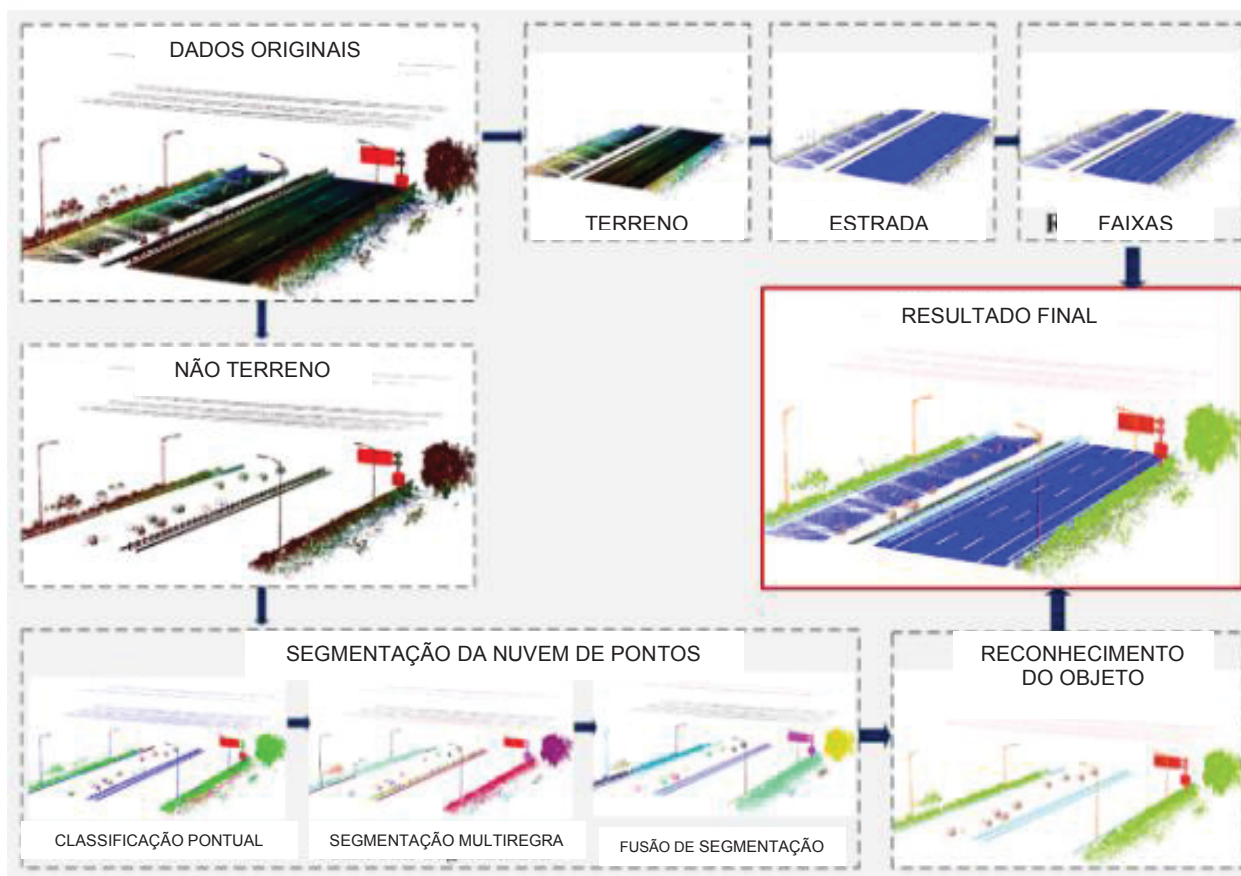


FONTE: YANG ET AL. (2016)

Yang et al (2016) inicialmente classifica terreno e não terreno usando o método proposto por Hernández and Marcotegui (2009). O próximo passo é a detecção da superfície da estrada e das pinturas de faixa, a partir dos dados de terreno e da combinação de feições geométricas e feições reflexivas. Os elementos não terreno foram segmentados em elementos individuais através de um esquema iterativo, que inclui classificação pontual, segmentação multi-regra e fusão de segmentos adjacentes, conforme apresentado na FIGURA 25. Finalmente, o framework de anotação semântica, que se beneficia de feições de vários tipos

(feições baseadas em pontos, feições baseadas em segmentos, feições baseadas em objetos e feições baseadas em contexto), é desenvolvido para obter a classificação de cada candidato a objeto.

FIGURA 25 - ETAPAS DE PROCESSAMENTO DA NUVEM DE PONTOS PARA A CRIAÇÃO DE MAPAS INTELIGENTES.




FONTE: YANG et al. (2016)

2.9 PROCESSAMENTO DIGITAL DE IMAGENS

Uma imagem pode ser definida como uma função bidimensional, $f(x,y)$ em que x e y são coordenadas espaciais (plano) e a amplitude de f em qualquer par de coordenadas $((x,y))$ é chamada de intensidade ou valor digital da imagem neste ponto. (GONZALEZ E WOODS, 2000). A Figura 26 apresenta um exemplo de uma imagem monocromática e a representação do pixel com seus respectivos valores digitais. O pixel é o elemento básico em uma imagem. Normalmente o pixel possui a forma quadrada ou retangular. Uma imagem é formada por vários pixels e a quantidade de pixels de uma imagem possui tamanho finito.

FIGURA 26 - DETALHE DOS PIXELS DA IMAGEM E SEUS RESPECTIVOS NÍVEIS DE CINZA



FONTE: A autora (2016)

Conforme apresentado na FIGURA 27, as funções de processamento de imagens digitais podem ser classificadas em duas categorias: por pixel ou por dado. Por pixel, está relacionado com técnicas de processamento. Por dado, está relacionado com os tipos de resultado de cada técnica. As etapas do fluxograma podem ser recursivas e tem o objetivo de apresentar as etapas de aplicação das metodologias. (GONZALEZ E WOODS, 2000).

FIGURA 27 - ETAPAS DO PROCESSAMENTO DE IMAGENS



FONTE: A autora (2016)

2.9.1 Funções por pixel

A captura ou aquisição da imagem é realizada por sensores ópticos. Pode ser realizada utilizando um único sensor ou vários sensores, bem como, sensores de linha ou matriciais.

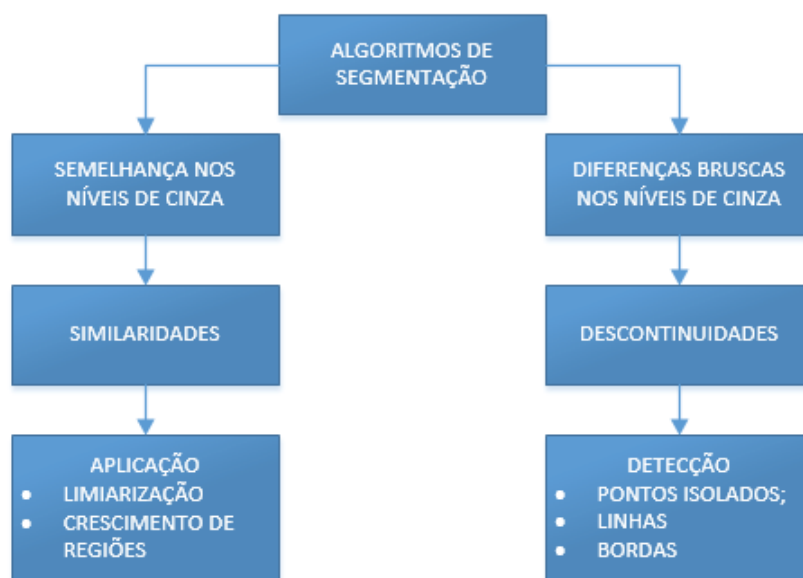
O realce e a restauração são filtragens realizadas sobre a imagem e que tem como objetivo melhorar a qualidade visual da imagem, ou seja, corrigir imperfeições ou defeitos incorporados na etapa da aquisição. O realce é realizado de forma intuitiva considerando a preferência humana, onde a imagem é manipulada de forma a fornecer um resultado adequado visualmente. A restauração tem o mesmo objetivo que o realce, melhora a qualidade da imagem, porém através de modelos matemáticos.

2.9.1.1 Segmentação

O processo de segmentação de imagens tem por objetivo separar uma imagem por unidades homogêneas, considerando algumas de suas características intrínsecas como, por exemplo, a uniformidade espectral dos pixels, sua textura ou

contraste. Normalmente os algoritmos de segmentação de imagens monocromáticas são baseados na busca pelas discontinuidades ou pelas similaridades dos níveis de cinza. As discontinuidades detectam elementos do tipo ponto, linha ou bordas e as similaridades detectam áreas. A FIGURA 28 apresenta o fluxograma dos algoritmos de segmentação conforme o comportamento dos valores digitais.

FIGURA 28 - ETAPAS DA SEGMENTAÇÃO



FONTE: Adaptado SALDANHA E FREITAS (2010)

A ideia principal dos métodos de segmentação é agrupar pixels de mesma propriedade, que fornecerá informações para a representação de determinada região de interesse, por isso a segmentação é um assunto muito utilizado em Visão Computacional e Reconhecimento de Padrões.

1.1.1.1.1 Métodos de Segmentação

Uma das maneiras de classificar os métodos de segmentação é separar os mesmos em dois grandes grupos: métodos de segmentação por similaridade e métodos baseados na detecção de diferenças na imagem.

As técnicas de discontinuidades são divididas em três tipos: pontos, linhas e bordas. Essas técnicas utilizam as vizinhanças entre os pixels, que devem ter fronteiras no nível de cinza suficientemente diferentes que permitam a detecção de um limite. A segmentação baseada nas bordas é a principal abordagem nesta categoria e depois a segmentação baseada em regiões. (GONZALEZ E WOODS, 2000). Os

algoritmos desenvolvidos para detectar essas discontinuidades usualmente usam a convolução, implicando no uso de máscaras.

A detecção de similaridade tem como fundamento a observação do interior dos objetos e não as fronteiras que os delimitam. Para tanto, parte da idealização que os pixels que compõe um objeto têm propriedades similares enquanto que os pixels de objetos distintos têm propriedades distintas. (SALDANHA E FREITAS, 2010). Os principais algoritmos que se baseiam em similaridades são: limiarização (*Thresholding*) e crescimento de regiões (*Region Growing*) e agrupamento (*Clustering*). Neste trabalho é usada a técnica de limiarização, que será detalhada a seguir.

1.1.1.1.2 Limiarização

A limiarização é considerada por Woods (2000) como uma das abordagens mais importantes e mais simples para a segmentação. Um objeto pode ser entendido como uma região formada por pixels contíguos que tenham em comum uma faixa de intensidades. Dessa forma, a limiarização usa a intensidade dos pixels para distinguir as regiões. (SALDANHA E FREITAS, 2010)

Como a limiarização gera uma imagem binária, o processo também é chamado de binarização. O processo todo se baseia na análise do histograma de frequências da imagem, onde as faixas de intensidade correspondem às bandas do histograma.

Existem dois tipos básicos de limiarização, uma que utiliza apenas um único limiar, ou *threshold*, como é conhecido, e outro que utiliza vários limiares. Conforme Marques Filho e et al (1999) a limiarização mais simples é aquela que o histograma é repartido em duas partes: o fundo e o objeto., onde os pixels cujo tom de cinza for maior ou igual a um certo valor de limiar (T) são convertidos em brancos e os demais em pretos, conforme FIGURA 29.

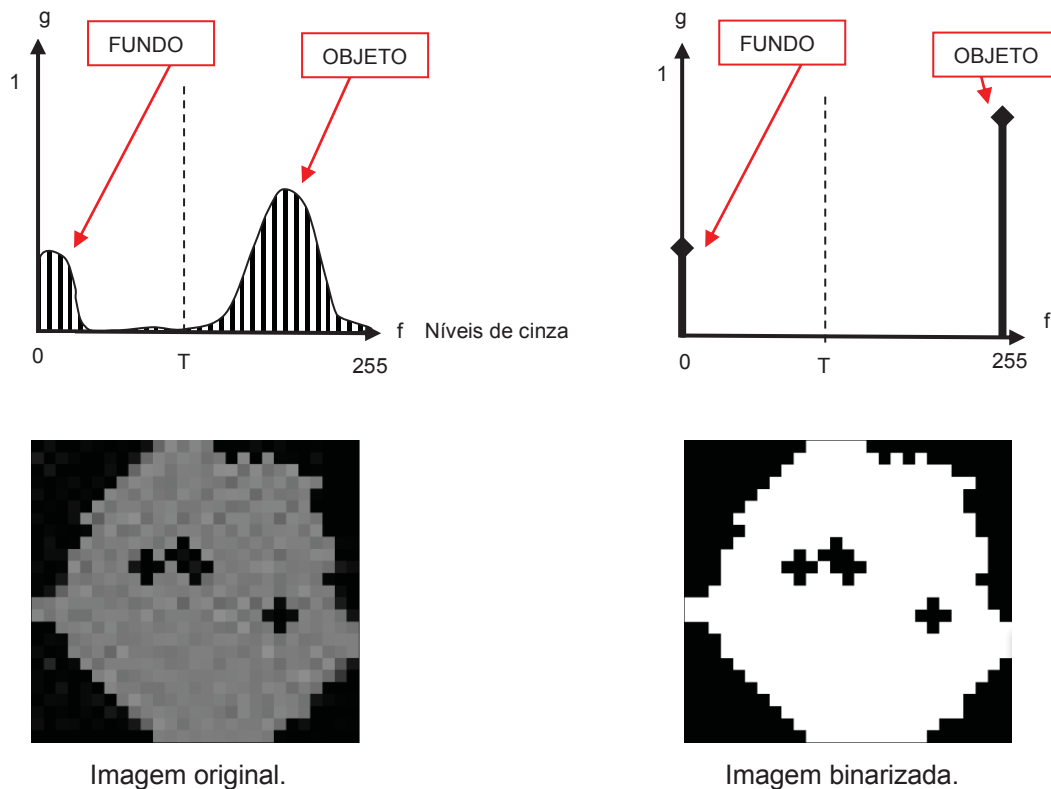
É uma técnica de processamento de imagens na qual uma imagem de entrada $f(x,y)$ de N níveis de cinza fornece uma imagem de saída limiarizada $g(x,y)$, em que o número de níveis de cinza é menor que N . A imagem $g(x,y)$ apresenta 2 níveis de cinza, onde os objetos são os pixels rotulados com 1 e o fundo os rotulados com 0 e T é o limiar, conforme apresentado na FIGURA 29 e EQUAÇÃO 16 (MARQUES FILHO E ET AL, 1999). É fundamental a escolha adequada do ponto

de corte T , pois é a partir dele que o fundo será separado do objeto, logo, o histograma é uma ferramenta utilizada para determinar esse limiar.

$$g(x,y) = \begin{cases} 1 & \text{se } f(x,y) \geq T \\ 0 & \text{se } f(x,y) < T \end{cases}$$

(16)

FIGURA 29 - LIMIAZIZAÇÃO DE UMA IMAGEM MONOCROMÁTICA UTILIZANDO LIMIAZ T



FONTE: (Marques Filho e et al, 1999).

Existem duas abordagens distintas quanto aos métodos de limiarização, uma global e outra local. A global utiliza apenas um único limiar T para toda a imagem, conforme exposto anteriormente e a local que divide a imagem em sub-regiões, onde cada uma tem seu limiar específico, conforme apresentado:

$$g(x,y) = \begin{cases} 255 & \text{se } f(x,y) < T_1 \\ 128 & \text{se } T_1 \leq f(x,y) < T_2 \\ 0 & \text{se } f(x,y) \geq T_2 \end{cases}$$

(17)

Serão apresentadas as técnicas de limiarização de Otsu, por entropia bidimensional e a de PUN, porém existem mais 40 técnicas para limiarização.

- Limiarização Bimodal de Otsu

Esse método é baseado na análise de discriminante. Os pixels de uma imagem com I níveis de cinza, são particionados em 2 classes C_0 e C_1 que podem representar o fundo e o objeto, porém essa partição se dará no nível de cinza. Portanto é indicado para resolver problemas que exijam vários limiares. Possui natureza não paramétrica e não supervisionada na seleção do limiar, onde um limiar ótimo é selecionado de forma automática e estável.

- Limiarização por entropia bidimensional

A separação do fundo e do objeto é realizada localizando o máximo de um critério de entropia bidimensional. A entropia é definida como um quantificador de randomicidade de uma imagem, quanto mais irregular, maior será seu número.

- Limiarização de Fischer


O método de Fischer consiste na localização de limiares nas classes de níveis de cinza. Esses limiares são encontrados através do critério da minimização da soma das inércias associadas às diferentes classes.

2.9.1.2 Morfologia Matemática

A morfologia é o estudo da forma e estrutura da matéria. É aplicada em várias áreas, na biologia, na sociologia, na matemática, no português, etc. Por exemplo, morfologia social é a parte da sociologia que estuda e classifica as estruturas e as formas de vida social. Neste trabalho será utilizada a morfologia matemática.

A morfologia matemática é uma abordagem do processamento digital de imagens que utiliza como base a Teoria dos Conjuntos para o estudo de estruturas geométricas existentes nas imagens. Considerando os conjuntos A e B, a relação de união, interseção e diferença entre os elementos desses conjuntos podem ser visualizadas na FIGURA 30.


FIGURA 30 - RELAÇÃO ENTRE OS ELEMENTOS NA TEORIA DOS CONJUNTOS



FONTE: WANGENHEIM. (2011)

A base da morfologia consiste em extrair informações relativas à geometria e topologia de uma imagem desconhecida pela transformação linear através de outra imagem conhecida, chamada de elemento estruturante, apresentada na FIGURA 31. A FIGURA 31 apresenta três imagens, onde a imagem (a) é um exemplo de imagem com seus respectivos valores de tons de cinza, a imagem (b) é o elemento estruturante que é uma imagem definida conforme a operação que será utilizada e a imagem (c) apresenta o resultado da operação.


FIGURA 31 - EXEMPLO DE UMA IMAGEM ORIGINAL, ELEMENTO ESTRUTURANTE E A IMAGEM RESULTANTE APÓS A MORFOLOGIA MATEMÁTICA.



FONTE: Menezes (2010)

O elemento estruturante é um pequeno conjunto ou sub-imagens usadas para examinar uma imagem buscando propriedades de interesse. O formato e o tamanho do elemento estruturante possibilitam testar e quantificar de que maneira o elemento estruturante está ou não está contido na imagem, conforme apresentado na FIGURA 32. (Gonzalez e Woods, 2000).

FIGURA 32 - TIPOS DE ELEMENTOS ESTRUTURANTES.



FONTE: GONZALEZ E WOODS (2010)

O elemento estruturante pode ser de qualquer tamanho e de qualquer forma, entretanto neste estudo será utilizado um elemento estruturante retangular com sua origem no pixel central. Os conceitos de reflexão e a translação são amplamente utilizados na morfologia matemática para formular as operações nos elementos estruturantes. (GONZALEZ E WOODS, 2000)

Conforme Gonzalez e Woods (2000) na maioria das vezes, o elemento estruturante é escolhido em função de convexidade, não convexidade, isotropia e anisotropia. Deve ser o mais simples possível e considerando uma imagem, é definido pelos pixels que o formam.


Os operadores morfológicos são divididos em quatro classes básicas: dilatação, erosão, abertura e fechamento. Existem várias formas de escrever as operações morfológicas.

A erosão é como um filtro que diminui ou afina os objetos de uma imagem binária, conforme apresentado na FIGURA 33. É uma transformação matemática que combina dois conjuntos usando vetores de subtração. Considerando A e B como conjuntos de Z^2 , a erosão de A por B, indicada por $A \ominus B$, é definida pela EQUAÇÃO 18.

A EQUAÇÃO 18 indica que o conjunto resultante da erosão de A por B é o conjunto de todos os pontos de z tal que B quando transladado de z , fique contido em A.

$$A \ominus B = \{z | (B_z \subseteq A)\} \quad (18)$$

FIGURA 33 -. IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO EROSAÇÃO (C)




FONTE: A autora (2016)

A dilatação binária é uma transformação morfológica que combina dois conjuntos usando a adição vetorial. Seu símbolo é $+$. A dilatação é como um filtro que aumenta ou expande os objetos de uma imagem binária, conforme é possível verificar na FIGURA 34. Considerando A e B como conjuntos de Z^2 , a dilatação de A por B, indicada por $A \oplus B$, definida por:

$$A \oplus B = \{z | (\hat{B}_z \cap A \neq \emptyset)\} \quad (19)$$

FIGURA 34 - IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO DILATAÇÃO (C).




FONTE: A autora (2016)

As operações de abertura (FIGURA 35) e fechamento (FIGURA 36) são variações das operações de erosão e dilatação. A abertura geralmente suaviza o contorno de um objeto, rompe as áreas estreitas e elimina as saliências finas. Considerando a EQUAÇÃO 20 a abertura de A por B é a erosão de A por B, seguida de uma dilatação do resultado por B. O fechamento geralmente funde as descontinuidades estreitas, elimina buracos e preenche as lacunas em um contorno. A EQUAÇÃO 21 apresenta que o fechamento de A por B é a dilatação de A por B, seguida pela erosão do resultado por B.

$$A \circ B = (A \ominus B) \oplus B \quad (20)$$


FIGURA 35- IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO ABERTURA (C).



FONTE: A autora (2016)

$$A \circ B = (A \oplus B) \ominus B \quad (21)$$

FIGURA 36 - IMAGEM ORIGINAL (A), ELEMENTO ESTRUTURANTE (B) IMAGEM APÓS A OPERAÇÃO FECHAMENTO (C).




FONTE:A autora (2016)

2.9.1.3 Análise de Componentes Conexos

A conectividade entre os pixels é a forma que os pixels se relacionam considerando sua organização. Um pixel tem quatro vizinhos de borda e quatro vizinhos de diagonal, conforme apresentado na FIGURA 37.

Como os pixels não apresentam a mesma propriedade em todas as direções, esta propriedade obriga que seja definido o tipo de conectividade que será utilizada, ou B4 (considerando apenas os vizinhos de borda) ou B8 (considerando os vizinhos de borda e os de diagonal). E as distâncias entre um ponto e seus vizinhos não é a mesma para qualquer vizinho. Será 1 para os vizinhos de borda e $\sqrt{2}$ para aqueles na diagonal.

FIGURA 37 - TIPOS DE CONECTIVIDADE DOS PIXELS EM RELAÇÃO AO PIXEL CENTRAL.



FONTE: Adaptado autora (2016)

2.9.1.4 Rotulação de componentes conexos

A rotulação é fundamental para a contagem de objetos e muito aplicada na área de visão computacional. O rótulo é uma região que é atribuído um valor, normalmente é chamado de *label*. (GONZALEZ E WOODS, 2000)

Basicamente, os algoritmos examinam uma imagem, percorrida pixel a pixel por um processo de varredura onde os componentes conectados são rotulados provisoriamente. Cada vez que o pixel for verificado, seus vizinhos também são e um rótulo apropriado é designado para ele.

Existem vários algoritmos para rotulação de componentes conexos, pode-se citar algoritmos *multi-pass*, *two-pass* e *one-pass*.

2.9.1.5 Análise das Componentes Principais


A análise de componentes principais, também conhecido como PCA (*Principal Components Analysis*), é um método que tem por objetivo transformar um conjunto de variáveis originais em outro conjunto de variáveis de mesma dimensão denominadas de componentes principais. É uma técnica da estatística multivariada que transforma linearmente um conjunto de dados, que possuem determinada correlação, em um conjunto menor, ou seja, reduz a dimensionalidade dos dados, sem perder a característica do conjunto original de dados. (Varela, 2008).

Considerando as observações com determinado número de características "p" e determinado número de "n" variáveis é apresentada a matriz Z , EQUAÇÃO 22.

$$X = \begin{bmatrix} x_{11} & \cdots & x_{np} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{np} \end{bmatrix} \quad (22)$$

A correlação pode variar de +1 até -1. Valores perto de +1 indicam alto grau de correlação positiva, valores perto de -1 indicam forte correlação negativa e valores próximos a 0 indicam fraca correlação. Na FIGURA 38 é apresentada a correlação entre duas variáveis.

FIGURA 38 - CORRELAÇÃO ENTRE DUAS VARIÁVEIS X1 E X2.



FONTE: Varela, 2008

As observações são representadas por uma nuvem de pontos em um espaço multidimensional, com um eixo para cada uma das variáveis. A média de cada variável é definida pelo centroide dos pontos e a variância é a média dos quadrados da diferença dos pontos com relação a média de cada variável. Essas medidas são unidimensionais. A covariância sempre é medida entre duas

dimensões e sua diagonal principal é a variância, pois a covariância dele mesmo é a própria variância.

A partir dos valores das médias e variâncias, é possível calcular a covariância.

$$C(X, Y) = \frac{\sum_{i=1}^n (X_i - \mu)(Y_i - \mu)}{(n - 1)} \quad (23)$$

$$C = \begin{bmatrix} \hat{V}ar(X_1) & \cdots & \hat{C}ov(X_1 Y_n) \\ \vdots & \ddots & \vdots \\ \hat{C}ov(Y_n X_1) & \cdots & \hat{V}ar(Y_n) \end{bmatrix} \quad (24)$$

onde:

C= é a matriz de covariância;

n= quantidade de variáveis

x= valor da variável

μ = é a média das variáveis

Normalmente, como a matriz C é simétrica e real e as variáveis quando apresentam características em medidas diferentes entre si são normalizadas. A normalização pode ser feita com média 0 e variância 1, ou com variância 1 e média qualquer.

As componentes principais são determinadas resolvendo a EQUAÇÃO 24, onde C é a matriz de covariância, λ é o autovalor e I é a matriz identidade. Portanto os autovalores são escalares não nulos que solucionam o determinante.

$$\det[C - \lambda I] = 0 \quad (25)$$

Os autovalores são números que representam quanta variação existem nos dados em determinada direção, que é o autovetor. Ou seja, para cada autovalor existe um autovetor, são pares. O autovetor com o autovalor mais elevado é a componente principal.

$$\lambda \Sigma = \begin{bmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \lambda_2 & \vdots \\ 0 & \cdots & \lambda_3 \end{bmatrix} \quad (26)$$

A contribuição de cada componente principal é expressa em porcentagem e é calculada dividindo-se a variância de cada variável pela variância total. Sua importância é avaliada através desse cálculo, ou seja, pela proporção de variância total explicada pelo componente.

O grau de influência que cada variável tem sobre a componente pode ser calculada através dos pesos de cada variável sobre um determinado componente. Posteriormente comparam-se os valores obtidos. Conforme EQUAÇÃO 26, w_1 é o peso de X_1 e a_{11} é o autovalor.

$$w_1 = \frac{a_{11}}{\sqrt{\text{Var}(X_1)}} \quad (27)$$

A PCA possui vantagens e desvantagens. A principal vantagem é a eliminação de ruídos experimentais, devido essas variáveis não estarem correlacionadas. É gerada uma nova matriz a partir das variáveis correlacionadas, ortogonais entre si, chamadas de componentes principais. A principal desvantagem é a sensibilidade a *outliers* quando existem muitos zeros na matriz.

2.9.2 Classificação com Redes Neurais


As RNA's Redes Neurais Artificiais são uma ferramenta computacional que pode ser aplicada em diversas áreas, uma delas é o reconhecimento de padrões. Utiliza um modelo matemático que se tem como base a estrutura neural dos organismos inteligentes.

Segundo Haykin (2008), o cérebro é um computador altamente complexo, não-linear e paralelo, capaz de armazenar conhecimento baseado em experiência. Os neurônios são considerados como as unidades básicas de processamento do cérebro. De modo análogo, modelos simplificados dos neurônios biológicos constituem as RNAs.

Os neurônios biológicos estão conectados uns aos outros através de conexões sinápticas. Essas ligações conduzem a informação de um neurônio à outro, bem como, os pesos multiplicam a informação recebida a entrada. Alguns estudos apresentaram que memória da estrutura neural não está nos neurônios, mas sim nos pesos das sinapses. Estes pesos é que são alterados, ou não, quando recebem mais informação ou quando estão em processo de aprendizagem.

A FIGURA 39 apresenta um modelo simplificado de um neurônio biológico. As setas indicam o fluxo de informações e os dendritos, axônio, corpo celular e terminações são as regiões. O estímulo se propaga através do neurônio quando a soma dos estímulos de entrada supera um valor limiar, ou seja, o *threshold*.

FIGURA 39- REPRESENTAÇÃO SIMPLICADA DE UM NEURÔNIO BIOLÓGICO.



FONTE: Adaptado Arbib (2003)

A FIGURA 39 apresenta um modelo de um neurônio artificial que é considerado como uma unidade de processamento onde o resultado do somatório de todos os sinais de entradas $x_1, x_2 \dots x_p$ com seus respectivos pesos $w_{k1}, w_{k2} \dots w_{kp}$ e do polarizador θ_k é aplicado a uma função de ativação φ que produzirá um sinal de saída y_k . A TABELA 2 apresenta as equivalências entre um neurônio biológico e um artificial.

TABELA 2 - EQUIVALENCIA ENTRE OS NEURÔNIOS

NEURÔNIO BIOLÓGICO	NEURÔNIO ARTIFICIAL
Corpo celular ou soma	Neurônio
Dendritos	Entrada
Axônio	Saída
Sinapse	Peso

FONTE: Adaptado Negnevitsky (2002)

A saída do neurônio depende de uma função de ativação. Existem três tipos de função de ativação: *threshold*, linear e sigmoideal. A maioria das redes neurais utiliza a função sigmoideal, que apresenta propriedades assintóticas e de suavidade.

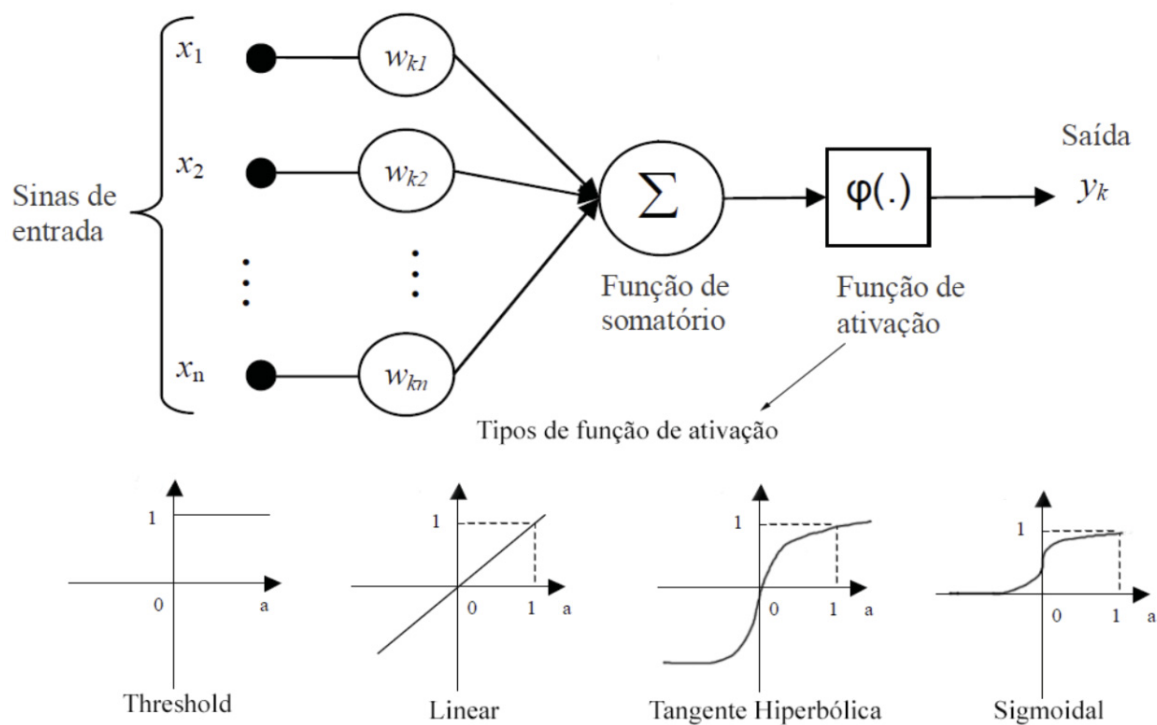
No caso onde é necessário que a saída da função sigmoial varie entre -1 e 1 utiliza-se a função tangente hiperbólica. A TABELA 3 apresenta os tipos de função de ativação para o treinamento da RNA, bem como, as equações envolvidas nas funções.

TABELA 3 - FUNÇÕES DE ATIVAÇÃO

NOME	FÓRMULA	DERIVADA
Threshold	$f(u) = \begin{cases} 1 \rightarrow u > 0 \\ 0 \rightarrow u \leq 0 \end{cases}$	-
Linear	$f(u) = au + b$	a
Sigmóide	$f(u) = \frac{1}{1 + e^{-u}}$	$f(u)[1 - f(u)]$
Tangente Hiperbólica	$f(u) = \tanh \frac{x}{2} = \frac{1 - e^{-x}}{1 + e^{-x}}$	

FONTE: Adaptado Negnevitsky (2002)

FIGURA 40 - REPRESENTAÇÃO SIMPLICADA DE UM NEURÔNIO ARTIFICIAL.




FONTE: Adaptado Arbib (2003)

2.9.2.1 Arquitetura das redes neurais

A arquitetura da rede é organização dos neurônios, é a forma como estão dispostos. Uma rede neural pode ser representada por um grafo direcionado, conforme apresentado na FIGURA 41, onde o nó representa um neurônio e as arestas representam as entradas ou a saída de um neurônio. A forma como os neurônios são conectados define diferentes topologias de rede e está relacionada ao algoritmo a ser utilizado no seu treinamento. (HAYKIN, 2009, p. 21):

Conforme FIGURA 41, existem basicamente três camadas na RNA: uma camada de entrada, uma camada intermediária e uma camada de saída, sendo que nem todas possuem camada intermediária. Os sinais de entradas da rede correspondem aos atributos ou características que são convertidos em valores numéricos, entre 0 e 1, independente se for um atributo quantitativo ou qualitativo. Os sinais de saídas representam a solução da rede neural que também serão os valores utilizados durante o treinamento.

FIGURA 41- ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL



. FONTE: Adaptado Negnevitsky (2002)

As principais arquiteturas em RNAs são as redes *feedforward* de uma camada, as redes *feedforward* de múltiplas camadas e as redes recorrentes. O termo *feedforward* indica que os sinais se propagam apenas da entrada para a saída.

2.9.2.2 Backpropagation

O processo de aprendizagem consiste em encontrar os pesos adequados para um conjunto de dados. Esse processo pode ser classificado como: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por esforço. O aprendizado supervisionado baseia-se que o erro da rede é conhecido pelo supervisor ou tutor, dessa maneira é possível utilizar o erro calculado e o vetor de entrada para se obter os pesos. O aprendizado não supervisionado os pesos são calculados a partir da estatística resultante dos dados de entrada e o aprendizado por esforço é uma mesclagem dos outros dois tipos.

Segundo Andrade (2003), após a escolha do tipo e arquitetura da rede a ser utilizada na construção do modelo, definidos os parâmetros que servirão de entradas a rede e as saídas que se quer obter e coletados os dados referentes ao fenômeno a ser modelado, pode-se iniciar o processo de treinamento da rede neural.

O treinamento é um processo iterativo em que os dados de entrada são aplicados até a convergência do algoritmo e os erros sejam aceitáveis. O objetivo do treinamento é ajustar os pesos da melhor maneira possível.

Neste estudo será utilizado o algoritmo de aprendizado supervisionado *backpropagation*, como o próprio nome diz, a retropropagação dos erros calculados das saídas em relação as entradas. O erro calculado na saída de um neurônio é multiplicado pela derivada da função de ativação daquele neurônio e propagado para a sua entrada. Este valor então é enviado para todos os neurônios da camada anterior pesado pelas respectivas sinapses.

A equação básica do algoritmo *backpropagation* é:

$$w_{k+1} = w_k - \alpha_k \nabla_k(F_0) \quad (25)$$

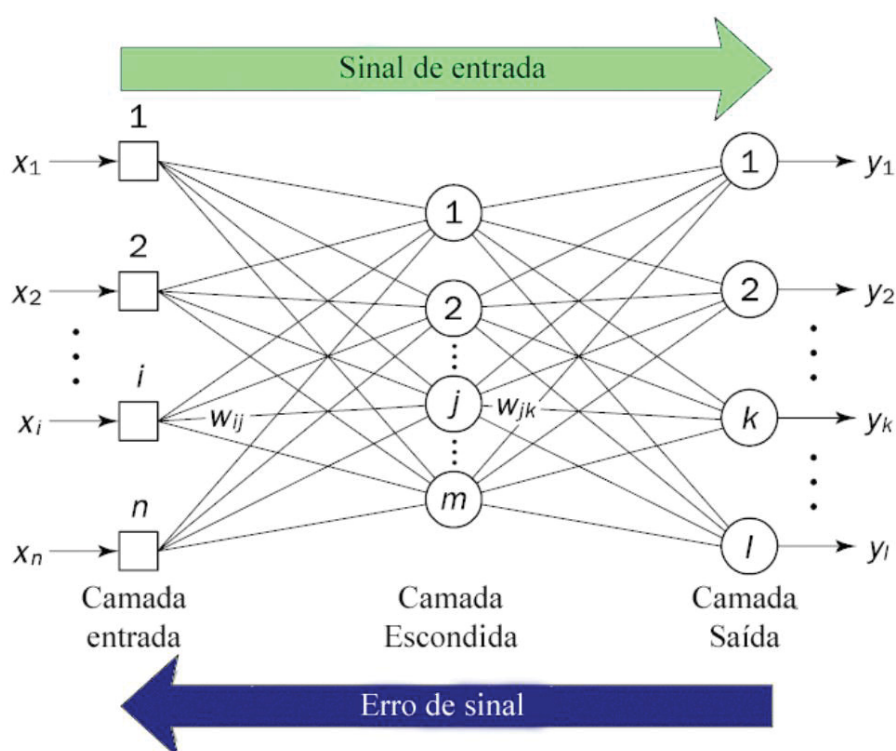
onde:

- w_{k+1} = é o vetor de pesos sinápticos no instante $k + 1$
- w_k = é o vetor de pesos sinápticos no instante k
- α_k = é uma constante chamada passo de treinamento
- $\nabla_k(F_0)$ = é o vetor gradiente da função objetivo

Segundo Haykin (2009), o processo de treinamento é constituído de duas fases, conforme apresentado na FIGURA 42:

1. Na fase *forward* (para frente) ocorre a propagação do sinal de entrada ao longo da rede.
2. Na fase *backward* (para trás) um sinal de erro é produzido através da comparação da saída obtida com a saída desejada. Este sinal é propagado *para trás* ao longo da rede. Nesta fase ocorre a correção dos pesos.

FIGURA 42 - ARQUITETURA DE UMA REDE BACKPROPAGATION



FONTE: Adaptado Negnevitsky (2002)

3 MATERIAIS E MÉTODOS

Neste capítulo serão apresentados os principais equipamentos que fazem parte do sistema Leica Pegasus One, bem como a metodologia aplicada para a detecção e identificação dos postes e placas da área de estudo.

3.1 MATERIAIS

3.1.1 Sistema terrestre móvel Pegasus One

Os dados utilizados neste estudo foram capturados pelo sistema móvel Pegasus One. O sistema suíço foi lançado na feira Hexagon Live 2013 nos Estados Unidos e pertence a empresa Leica Geosystem. Chegou ao Brasil apenas em 2014. Ele é composto por sensor LIDAR, um receptor GNSS, um IMU, um DMI e o diferencial entre os outros sistemas são as seis (6) câmeras digitais métricas, instaladas na frente, atrás e nas laterais da plataforma do veículo. Os componentes estão apresentados detalhadamente na FIGURA 43.


FIGURA 43 - COMPONENTES DO SISTEMA PEGASUS ONE



FONTE: Adaptado Pegasus Roadway Presentation (2015)

O sistema inicialmente gera uma trajetória através das informações da solução GNSS e IMU, em conjunto, uma varredura sem registro e as fotos são sincronizadas, conforme apresentado na (FIGURA 44). Essa sincronização é realizada a partir de algoritmos proprietários e suas respectivas otimizações são realizadas, em algumas vezes, automaticamente sem parametrização. Após um processamento, o resultado do levantamento é um arquivo de pontos devidamente orientado num sistema de projeção e imagens orientadas conforme a nuvem de pontos.

FIGURA 44 - FUNCIONAMENTO DE UM MAPEAMENTO MÓVEL



FONTE: Adaptado apresentação Leica Geosystem 2014.

O Pegasus One apresenta a vantagem em ser *plug and play*, ou seja, sua instalação é rápida e combinada com um software de fácil operabilidade, apresentado na FIGURA 45, evitando assim a necessidade de um treinamento exaustivo antes de um levantamento.

FIGURA 45 - INSTALAÇÃO DO SISTEMA (A) E VEÍCULO COM O SISTEMA INSTALADO (B)





FONTE: A autora (2016).

O sistema é capaz de coletar um milhão de pontos por segundo, 12 fotos por segundo, operando numa velocidade normal de 60 km/h. O sistema é composto por uma unidade de aquisição, uma unidade de controle e uma unidade de alimentação.

A unidade de aquisição é o conjunto de instrumentos que fazem a captura dos dados. Ela é composta pelo sensor laser, GNSS, IMU, câmeras digitais e um odômetro. O detalhamento dos equipamentos está apresentado nos itens a seguir:

QUADRO 2 - EQUIPAMENTOS DO SISTEMA PEGASUS ONE

Componente	Configurações
<p>Sensor Laser Z+F Profiler 9012</p> 	<ul style="list-style-type: none"> • Coleta um milhão de pontos por segundo, • Velocidade de rotação de 200 Hz, • Resolução de 5 cm até 50km por hora; • Alcance de 120m.
<p>INS Novatel SPAN FSAS 200Hz</p> 	<ul style="list-style-type: none"> • Conecta um receptor GNSS com um IMU; • Precisão de 20 mm; • Esse conjunto é responsável pelo georreferenciamento do veículo.

<p>Cameras Digitais</p> 	<ul style="list-style-type: none"> • Seis câmeras digitais métricas • Cobertura de 360° na horizontal e 70° na vertical; • Sobreposição de imagens para garantir a estereoscopia 3D,
<p>Odômetro</p> 	<ul style="list-style-type: none"> • Instalado na roda do veículo; • Fornece 1000 pulsos por rotação; • Mantém a precisão da trajetória em lugares susceptíveis a perda de sinal; • O processamento dos dados do odômetro é realizado em conjunto com a trajetória gerada pelos outros sensores e baseado nos filtros de Kalman.
<p>FONTE: Todos os dados e imagens são do Manual Pegasus One</p>	

O equipamento pesa aproximadamente 40 kg e foi fixado na parte superior de um veículo utilitário marca Fiat modelo Dobló. O sistema não requer nenhum suporte especial, apenas barras transversais para a sustentação do equipamento. Como o sensor laser realiza uma varredura em 360 graus de cobertura, para que não ocorra obstrução do pulso, o sistema é posicionado num ângulo de 40 graus em relação à base do teto do veículo, conforme apresentado na FIGURA 46.

FIGURA 46 - SISTEMA LASER TERRESTRE MÓVEL PEGASUS ONE COM INDICAÇÃO DO ÂNGULO CORRETO PARA INSTALAÇÃO



FONTE: A autora (2016)

A unidade de alimentação baseia-se num conjunto de baterias com capacidade de 10 horas de duração, fica na parte traseira e é ligado ao sistema através de um cabo que é conectado na unidade até o sistema instalado acima do veículo, conforme apresenta na FIGURA 47.


FIGURA 47 - FONTE DE ALIMENTAÇÃO.



FONTE: A autora (2016)

A unidade de controle de aquisição dos dados, apresentado na FIGURA 48, é composta por um laptop de bordo com uma configuração compatível a quantidade de dados a serem armazenados. A unidade gerencia a captura e apresenta a trajetória que está sendo gerada, bem como, outras informações importantes como número de satélites, PDOP e qualidade das imagens, em tempo real.

FIGURA 48 - UNIDADE DE CONTROLE.




FONTE: A autora (2016)

O equipamento, levantamento e processamento dos dados foram realizados com a presença do autor e cedidos pela empresa Esteio Engenharia e Aerolevantamentos S.A para a UFPR para fins acadêmicos. O levantamento foi realizado dia 08 de abril de 2014.

3.1.2 Área de Estudo

Á área levantada foi uma rua de acesso aos blocos dentro do campus da Universidade Federal do Paraná, no município de Curitiba, PR, conforme mapa de localização apresentado na FIGURA 49. A área está compreendida pelas coordenadas $25^{\circ}27'15,49''\text{S}$, $49^{\circ}14'15,04''\text{O}$ e $25^{\circ}26'45,31''\text{S}$, $49^{\circ}13'47,49''\text{O}$, a varredura demorou duas horas e possui 2,3 km lineares.

FIGURA 49 - MAPA DE LOCALIZAÇÃO.



FONTE: A autora (2016)

Este mapa de localização foi gerado a partir de dados LIDAR. É uma composição da hipsometria fornecida pela altimetria, acrescido dos dados de intensidade do sinal.

3.1.3 Coleta de dados

O percurso foi realizado em apenas um sentido, iniciando no ponto 1 e finalizando no ponto 2, conforme apresentado na (FIGURA 49). O sistema garante a captura de dados numa velocidade de 60 km/h, neste caso, como a velocidade permitida da faixa era de 30 km/h, a aquisição dos dados foi realizada nessa velocidade. A densidade média de pontos para a área de estudo foi de 2.400 pontos por m², suficiente para detalhar os postes e placas que são o objetivo de estudo dessa dissertação.

A equipe formada para o levantamento foi de um motorista, um técnico responsável pelo rastreamento dos dados da base GNSS, um técnico responsável pela operação do software de captura dos dados e um auxiliar.

Quando o sistema é iniciado, é necessário que o veículo esteja em um lugar aberto, livre de obstrução de sinal GPS. Em seguida é realizado o alinhamento estático e o dinâmico para garantir que o sistema IMU/GPS inicie corretamente.

No alinhamento estático o veículo deve ficar ligado e parado por aproximadamente 2 minutos, até que o software forneça a mensagem que o processo está concluído. Posteriormente, no alinhamento dinâmico o veículo deve estar em movimento e realizando-se vários zigue-zagues até que o software indique que o processo está concluído.

Antes da aquisição dos dados ser iniciada, o veículo deve permanecer parado e ligado durante 2 minutos. Esse procedimento é chamado de alinhamento final estático e tem como objetivo aumentar a qualidade da trajetória no pós-processamento. Após a aquisição dos dados, o veículo deve permanecer parado e ligado durante 2 minutos para encerrar o processo garantia de qualidade da trajetória.

Como o levantamento tinha por objetivo testar o equipamento e cadastrar elementos próximos dentro da faixa de domínio da rua, não houve a necessidade de dupla passada para recobrimento de elementos não capturados por oclusão ou por

qualidade depreciada. Parte do percurso possui várias árvores próximas ao corredor, prejudicando o sinal GNSS.

A trajetória apresentada na (FIGURA 50) mostra o resultado da solução GNSS. Os pontos em "verde" são os pontos com qualidade alta e os pontos em "roxo" com qualidade baixa. Por exemplo, no ponto A da mesma figura, foi obtida uma solução com qualidade baixa, qualidade "*FLOAT*" e tem apenas 5 satélites no momento da captura. No exemplo B, a solução foi com qualidade alta, qualidade "*FIXED*", com 15 satélites.

FIGURA 50 - RESULTADO DA TRAJETÓRIA.



FONTE: Dados da Trajetória, a autora (2016) e imagem Google Earth (2014)

Conforme IBGE 2008, com a precisão na ordem de 1 a 10 ppm, o posicionamento relativo cinemático consiste em se determinar um conjunto de coordenadas para cada época de observação, onde um receptor ocupa a estação de referência enquanto o outro permanece estacionado ou se deslocando sobre as feições de interesse. Portanto, no posicionamento cinemático, embora a antena

esteja em movimento, a trajetória é descrita por uma série de pontos. Isso tem como consequência a necessidade do usuário dispor de no mínimo cinco satélites para realizar o posicionamento.

As diferenças de qualidade durante a trajetória são ocasionadas pelas obstruções encontradas no percurso. As obstruções com maior ocorrência são carros e árvores. A estação GNSS utilizada como base foi a UFPR da RBMC, cujo relatório de informação da estação está apresentada no ANEXO 1.

3.2 MÉTODOS

O presente estudo apresenta a metodologia dividida nas seguintes etapas:

- Pré-processamento dos dados,
- Detecção de elementos verticais,
- Agregação de pixels,
- Cálculo de parâmetros de forma e;
- Classificação de postes e placas com redes neurais.

3.2.1 Pré-processamento

O resultado do levantamento é validado na etapa de processamento dos dados. Nesta etapa a nuvem de pontos é gerada conforme a parametrização estabelecida pelos softwares do sistema Pegasus One® fornecidos pelo fabricante Leica. Os dados foram processados pela autora na empresa Esteio Engenharia e Aerolevante S.A. As etapas, softwares e fabricantes utilizados são descritos a seguir. Todos os softwares são de domínio privado.

O computador utilizado no processamento foi um computador Intel Core i7 com processador de 3.2GHz, 32GB de memória RAM e sistema operacional Windows® 7 64 bits.

3.2.1.1 Processamento da trajetória IMU/GNSS


O processamento da trajetória IMU/GNSS foi realizado com o software Inertial Explorer® da Novatel. Como citado anteriormente, a trajetória interfere diretamente na qualidade dos dados coletados. Neste sentido, a solução de GPS/IMU é considerada uma das etapas mais importantes no MTLs, devido a sua

complexidade. O levantamento é executado normalmente em áreas onde existem obstruções para o sinal GPS, como árvores e prédios ou que podem gerar intervalos sem informação na trajetória. A Leica e a Novatel recomendam que a varredura seja realizada considerando uma constelação de no mínimo 4 satélites e um PDOP menor que 5 para que a trajetória seja satisfatória.

Todos os resultados qualitativos e posicionais da trajetória podem ser verificados através de gráficos. Os gráficos apresentam resultados estatísticos e os mais utilizados para análise são a precisão de posição estimada, representado por linhas, o gráfico número de satélites e PDOP, representados por barras.

Na (FIGURA 51) está apresentado o gráfico de precisão de posição estimada, que fornece os resultados de precisão em E (leste), N (norte) e H (altura) e o resultado da precisão nos 3 eixos "trace". Os picos representam a perda de sinal ou qualidade deteriorada durante a captura, ou seja, como o levantamento é realizado em movimento, qualquer obstrução gera um pico no gráfico. Para que o resultado seja satisfatório, a linha "trace", deve apresentar desvio padrão estimado até 0,05 m. No exemplo, ficou menor que 0,012 m a trajetória inteira, portanto o resultado é satisfatório. Após a análise dos gráficos e processamento da trajetória, os dados brutos do levantamento estão aptos para serem processados.

FIGURA 51 - GRÁFICOS DE SEPARAÇÃO COMBINADA



FONTE: A autora (2016)

3.2.1.2 Geração da nuvem de pontos

A próxima etapa após o processamento GPS/IMU é a geração da nuvem de pontos com o software Automatic Post Processing®. Este software utiliza a trajetória suavizada gerada pelo Inertial Explorer® para georreferenciar a nuvem de pontos e alinhar as seis câmeras métricas do sistema.


O formato dos arquivos da nuvem de pontos é o LAS. O LAS é um formato de arquivo binário que possibilita a manipulação de dados tridimensionais. É de domínio público, sendo uma alternativa para sistemas proprietários que utilizavam apenas o formato ASCII. O formato ASCII pode assumir várias configurações de informações e atributos, dificultando a troca de informações entre usuários e diferentes softwares.

3.2.1.3 Verificação da nuvem de pontos.

Após o processamento e geração dos arquivos LAS, os dados foram verificados no software ArcExplorer®. A Leica Geosystem desenvolveu um aplicativo para a visualização da nuvem de pontos em conjunto com as imagens capturas das seis câmeras. O sistema gera arquivos em blocos segmentados por tamanho.

A FIGURA 52 apresenta um exemplo da tela do software ArcExplorer. Na parte superior são as imagens referentes as câmeras e na parte inferior a nuvem de pontos laser.

FIGURA 52 - TELA DO ARC EXPLORER COM A TRAJETORIA E OS DADOS.



FONTE: A autora (2016)

A verificação consiste apenas numa análise visual das falhas que ocorreram durante a captura dos dados ou problemas nas sobreposições das faixas. Normalmente são realizadas mais de uma passada com o objetivo de cobrir elementos que não captados por oclusões. Os dados captados não apresentaram falhas significativas que interferissem nos resultados finais.

3.2.2 Detecção de elementos verticais

Com os dados tridimensionais devidamente processados e verificados, foi iniciado o processo de detecção dos postes e placas.

Esta etapa consiste dos seguintes passos:


- a) Organização da nuvem de pontos;
- b) Classificação de objetos acima do terreno com Terrascan;
- c) Detecção de postes por análise de densidade de pontos ao longo da vertical;
- d) Redução de ruído por morfologia matemática.

3.2.2.1 Organização da nuvem de pontos

O conjunto de dados original é formado por faixas no total de 10 arquivos no formato LAS. Cada arquivo tem aproximadamente 19 milhões de pontos e é acompanhado por um arquivo de metadados com informação de início e fim de gravação, extensão, tempo GPS, densidade de pontos, medidas de offset do laser em relação ao IMU.

A alta quantidade de pontos laser inviabiliza o tratamento dos dados em alguns softwares como o Matlab®, portanto o conjunto de pontos foi organizado em 18 arquivos conforme a articulação apresentada na FIGURA 53 acompanhando a trajetória percorrida pelo veículo.

FIGURA 53 - ARTICULAÇÃO DE CORTE DAS FOLHAS



FONTE: A autora (2016)

A área urbana deste estudo é formada por alguns elementos que não pertencem ao objetivo do presente estudo. A classificação desses elementos, como terreno, edificações, árvores e carros foram realizados através do software Terra Scan® que possui algoritmos próprios para classificação automática. Com esse procedimento, esses elementos podem ser retirados, ou não, da nuvem de pontos conforme a necessidade.

3.2.2.2 Classificação do terreno, prédios e veículos.

A classificação do terreno foi realizada com a ferramenta *Classify Hard Surface*. Essa rotina classifica os pontos que se referem ao terreno, criando iterativamente um modelo de superfície triangulada. É indicada para classificação de áreas realizadas com MTLs. O algoritmo é baseado na análise da declividade onde a ideia básica é a observação de que grandes diferenças de altura entre dois pontos próximos sejam pouco provável causada pela inclinação do terreno. A causa mais provável seja que o ponto mais alto não seja terreno, portanto define-se uma

diferença de altura máxima e os pontos que extrapolam são considerados não terreno.


Essa ferramenta é mais adequada para a classificação de estradas pavimentadas porque possui parâmetros que se ajustam a planos locais. Consideram uma tolerância muito baixa de variação do terreno em relação a um plano, bem como, uma baixa declividade do terreno.

Como a UFPR apresenta pouca variação altimétrica, os valores de declividade e ângulo de iteração são valores baixos. Essa ferramenta é indicada porque o levantamento foi realizado apenas nas ruas pavimentadas, caso contrário, seriam outras as rotinas indicadas.

A segunda classificação foi referente às edificações com a ferramenta *Classify Building*. Essa rotina classifica as edificações pelas superfícies planas e exige que os pontos referentes ao terreno já tenham sido classificados. Para a detecção de uma edificação não só características geométricas do um segmento (posição, localização, orientação, etc.) são consideradas. Características radiométricas e topológicas são avaliadas nesse algoritmo. A reflectância dos pontos da edificação e a relação espacial entre segmentos são utilizados para a classificação

Os parâmetros utilizados são o tamanho mínimo de área para iniciar a busca e a diferença máxima permitida em Z entre os pontos adjacentes. Os carros foram classificados com a mesma ferramenta que foi utilizada para a classificação das edificações, alterando apenas o valor de tamanho inicial mínimo da área de busca. A FIGURA 54 apresenta um exemplo de classificação com os carros em azul, o terreno em laranja e as edificações em vermelho.


FIGURA 54 - EXEMPLO DA CLASSIFICAÇÃO DO TERRENO, EDIFICAÇÕES E CARROS.



FONTE: A autora (2016)

A FIGURA 55 apresenta a vista em perfil da classificação do Terra Scan, com os mesmos elementos que foram apresentados na FIGURA 54, porém com ênfase nos elementos na cor branca, que são os não classificados, como árvores, postes e placas. O objeto de estudo serão os postes e placas.

FIGURA 55 - PERFIL DA CLASSIFICAÇÃO




FONTE: A autora (2016)

3.2.2.3 Análise de densidade de pontos em 2D

Essa etapa do processamento utiliza apenas a informação 2D da nuvem de pontos. O objetivo é segmentar as áreas que possuem uma densidade maior de pontos. Normalmente as estruturas verticais, como árvores, postes e edificações possuem uma densidade maior de pontos que as estruturas horizontais, como mostra a 56, com exceção de regiões que o automóvel teve alterações na velocidade ou paradas não programadas que aumentam a densidade de pontos durante a varredura.

56 - EXEMPLO DO PERFILAMENTO DE UMA ESTRUTURA VERTICAL.



FONTE: A autora (2016)

Para o cálculo de densidade de pontos, os mesmos foram projetados no plano horizontal dentro de uma grade regular. O tamanho da matriz foi calculada em função da área ocupada pelo levantamento (coordenadas E e N mínimas e máximas) e da resolução espacial estabelecida pelo autor. As EQUAÇÕES 26 e 27 apresentam os cálculos para a matriz, onde $E_{max} - E_{min}$ é a diferença entre os valores máximos e mínimos da componente E, $N_{max} - N_{min}$ é a diferença entre os valores máximos e mínimos da componente N e R é a média de quantidade de pontos por folha pela densidade média de pontos por m² (EQUAÇÃO 28).

$$\Delta x = \frac{E_{max} - E_{min}}{R} \quad (26)$$

$$\Delta y = \frac{N_{max} - N_{min}}{R} \quad (27)$$

$$res = \sqrt{\frac{Qtde\ média\ de\ pontos}{Densidade\ de\ pontos}} \quad (28)$$

A partir da determinação do tamanho da matriz a ser gerada, os valores da mesma são estabelecidos iterativamente pelos valores inteiros resultantes das EQUAÇÕES 29 e 30.

$$nCol = round\left(\frac{X - E_{min}}{res}\right) + 1 \quad (29)$$

$$nLin = round\left(\frac{Y - N_{min}}{res}\right) + 1 \quad (30)$$


A seguir, para cada ponto, foi calculada a coordenada em termos de linha e coluna dentro desta grade, usando suas coordenadas E e N.

$$Coluna = round\left(\frac{X - E_{min}}{rel}\right) + 1 \quad (31)$$

$$Linha = round\left(\frac{Y - N_{min}}{res}\right) + 1 \quad (32)$$

Assim, é conhecida a célula da grade correspondente, então, o valor encontrado nesta célula é acrescido de mais um, acumulando o total de pontos que correspondem a cada célula, como é mostrado na FIGURA 57. Nesta figura nota-se que os pontos correspondentes a um poste, por terem coordenadas planimétricas muito similares ocupam uma mesma célula, gerando um valor alto do acúmulo nesta célula.

FIGURA 57 - REPRESENTAÇÃO DOS PONTOS DE UMA ESTRUTURA VERTICAL NUMA MATRIZ.




FONTE: A autora (2016)

As células com elementos verticais foram separadas usando a técnica de limiarização. A limiarização é uma técnica de segmentação de imagens que consiste em separar uma imagem em regiões de interesse a partir da escolha de um ponto de corte, ou como é chamado, um *threshold*. Neste trabalho adotou-se um limiar *threshold* de 400 pontos por célula, idêntico para todas as folhas processadas. O resultado da limiarização é uma matriz de 0's e 1's onde as regiões que possuam vários 1's serão agrupadas e serão as possíveis placas e postes a serem detectáveis.

Um exemplo de limiarização está apresentado na FIGURA 58. A folha 18 originalmente possuía uma dimensão de 934534 x 3, ou seja 934534 pontos em cada uma das coordenadas X,Y,Z e após limiarização ficou com 2480x2740 células.

FIGURA 58 - EXEMPLO DO RESULTADO APÓS LIMIAZIZAÇÃO DA FOLHA 18.




FONTE: A autora (2016)

3.2.3 Agregação de pixels

Em função da resolução espacial da grade e da geometria dos postes e placas, estes elementos aparecem na grade de acúmulo não apenas como um ponto, mas ocupam varias células contíguas. Com a finalidade de suavizar a forma destas regiões e eliminar pequenos agrupamentos, foi aplicada a morfologia matemática.

Para fechar as áreas dos postes e placas foi aplicado O operador matemático de fechamento. O fechamento consiste em uma dilatação na imagem seguida de uma erosão. O elemento estruturante pode ser de qualquer tamanho e de qualquer forma, neste trabalho, foi escolhido a forma circular com o tamanho de 20 pixels, ou seja, um raio de 20 pixels. Após o fechamento, as áreas são agrupadas e os potenciais postes podem ser detectados, conforme apresenta a (FIGURA 59). A seguir, pequenas áreas foram eliminadas com o operador de abertura, usando o mesmo elemento estruturante.

FIGURA 59 - EXEMPLO DE UM ELEMENTO ESTRUTURANTE COM R=3




FONTE: A autora (2016)

A seguinte etapa tem por objetivo contar e detectar os elementos conexos na imagem binária, correspondentes aos objetos verticais presentes na nuvem de pontos. Isso foi realizado usando o algoritmo detecção de componentes conexos (GONZALEZ E WOODS, 2000). O resultado deste algoritmo é a rotulação de todos os pixels de cada agrupamento com um único número identificador. Assim, é possível caracterizar cada grupo pelo seu número, o que permite obter parâmetros geométricos dos grupos, como seu centroide e suas dimensões.

As regiões foram rotuladas através da função *bwlabel* do Matlab® e calculadas seu centroide com a função *regionprops*. *Bwlabel* é aplicado apenas em imagens binárias. A FIGURA 60 apresenta a folha 18, utilizada como exemplo no item anterior, que possui 9 elementos detectados e representados por suas localizações através de cruzetas.


FIGURA 60 - ELEMENTOS DETECTADOS APÓS SEGMENTAÇÃO E UM EXEMPLO.



FONTE: A autora (2016)

Com a localização definida, uma região em torno do centroide de 0,9 x 0,9m foi recortada na nuvem de pontos, assumindo que dentro delas se encontram os elementos detectados. Os pontos de cada objeto, foram a seguir recortados da nuvem de pontos original e arquivados separadamente. Um exemplo é mostrado na FIGURA 61.

FIGURA 61 - PONTOS DETECTADOS APÓS MORFOLOGIA MATEMÁTICA



FONTE: A autora (2016)


3.2.4 Cálculo de parâmetros geométricos

Os arquivos gerados na etapa anterior são lidos individualmente e classificados como postes ou não postes. Essa classificação utilizará informações dos objetos, como altura, direção, densidade de pontos e raio. Desta forma, ACP (Análise das Componentes Principais) e RANSAC foram alguns dos procedimentos matemáticos utilizados para a captura dessas informações.

3.2.4.1 Suporte e Topo

Os postes e placas que são os objetos desse estudo são estruturas verticais com alturas e raios diferentes. Como é mostrado na FIGURA 62, pode ser assumido que os mesmos são compostos de dois elementos, suporte e topo. Neste sentido, o primeiro procedimento realizado foi a separação do suporte do topo para que fosse possível calcular as dimensões destes elementos.

FIGURA 62 - EXEMPLO DE PLACA DETECTADA COM HISTOGRAMA ILUSTRATIVO.



FONTE: A autora (2016)

Inicialmente foi calculada a altura do elemento a partir dos valores máximos e mínimos na coordenada Z do mesmo. A seguir foi calculado o histograma de frequência vertical de pontos ao longo do objeto. Para isto, a nuvem de pontos foi fatiada em “n” trechos verticais e a quantidade de pontos em cada trecho foi calculada, como mostra a FIGURA 62. Tipicamente, o suporte tem menor quantidade de pontos, enquanto o topo teria mais pontos por trecho. Para a construção do histograma, é necessário definir o número de passos (ticks) do histograma, que é função da altura elementar de cada trecho vertical. A altura de cada tick é fixada pelo usuário. Assim, com a EQUAÇÃO 33 é possível calcular o número de ticks.

$$ticks = \text{ceil}\left(\frac{Z_{max} - Z_{min}}{step}\right) + 1$$

(33)

Para evitar perturbações que ocorrem perto do solo, como pedras ou vegetação perto do objeto, foi fixada uma altura mínima a partir da qual o objeto seria analisado. Com ela foi definida a base, ou a altura mínima a partir da qual seria analisado o objeto, usando a EQUAÇÃO 34.


$$Base = \left(\frac{\text{altura mínima}}{\text{step}} \right)$$

(34)

Uma vez definidos os parâmetros para a construção do histograma, o mesmo é calculado varrendo os pontos de cima para baixo. Um exemplo do seccionamento está apresentado na FIGURA 63. A altura desse elemento é de 2,63 metros, logo aplicando a EQUAÇÃO 33, são obtidos 54 ticks, ou seja cada step possui 0,05 metros. Considerando as tolerâncias pré-estabelecidas a altura mínima é de 1 metro, então o início da base representada em verde é 20 ticks e a base do topo em preto é 45 ticks. Como os valores máximos e mínimos foram calculados, a base é obtida pelo fracionamento da altura mínima pelo step, conforme EQUAÇÃO 34.

É assumido que o início do topo se caracteriza por um salto significativo nos valores do histograma, pois o topo possui área maior. Como mostra a figura 18, a a densidade média calculada ao longo do suporte é de 0,05. O início do topo é definido pelo primeiro local que apresenta uma densidade maior de pontos, que no exemplo apresentado é de 0,15 pontos por m².


FIGURA 63 - CÁLCULO DO INÍCIO DO SUPORTE E DO INÍCIO DO TOPO DE UMA PLACA



FONTE: A autora (2016)

Na (FIGURA 64) são apresentados o suporte e o topo separados após determinação dos seus pontos de início. Os pontos que pertencem ao topo, visivelmente identificam que se trata de uma placa redonda. Neste sentido, os próximos itens dessa pesquisa se tratam da captura das características e formatos dos diferentes postes e placas existentes no Campus.

FIGURA 64 - SUPORTE E TOPO DE UMA PLACA




FONTE: A autora (2016)

3.2.4.2 Determinação do raio dos suportes e placas

A varredura dos postes não foi completa, pois apenas um lado é geralmente visível (FIGURA 65). Assim sendo, o suporte, ou poste, não é completamente representado na nuvem de pontos. Além disso, muitas vezes outros elementos perto dos postes podem produzir pontos indesejados no recorte analisado.

Para estimar o raio do suporte, foi assumido que o mesmo é circular e vertical, e que poderia ser representado por um cilindro. A altura do mesmo é conhecida do passo anterior, faltando a estimativa de seu raio.

FIGURA 65 - PONTOS LASER DO CORTE TRANSVERSAL DO SUPORTE DE UMA PLACA E O DIÂMETRO CALCULADO POR RANSAC.



O algoritmo RANSAC foi escolhido para estimar o raio do suporte. Ele tem a capacidade de realizar uma estimativa robusta dos parâmetros do modelo, isto é, pode estimar os parâmetros com um alto grau de precisão, mesmo quando um número significativo de *outliers* está presente na nuvem de pontos (MARTIN E ROBERT, 1981).

O algoritmo RANSAC é composto por várias etapas que são executadas de forma iterativa, seguindo os passos:


1. Após a separação do poste ou placa em suporte e topo, o suporte é cortado e selecionado uma amostra desse conjunto de dados. O corte é realizado calculando-se a altura média do suporte para definir uma faixa do poste. As coordenadas X e Y dos pontos dentro desta faixa foram analisados.
2. Do conjunto de pontos disponíveis são selecionados 3 pontos e com eles é calculado o centro e o raio de uma circunferência que passa pelos mesmos.
3. A seguir é verificada se esta circunferência corresponde ao contorno do poste. Para isto é calculada a distância entre todos os pontos e o centro da circunferência. Se a estimativa estiver correta, a diferença será nula.

Como existem pequenas variações nos pontos, o valor dificilmente é nulo, assim que é buscado o raio associado à diferença mínima.

4. Caso a diferença ficar acima de zero, os passos 2 e 3 são repetidos, armazenando sempre o menor valor do erro e o raio correspondente.
5. Para evitar processos muito longos, um número máximo de 500 iterações foi fixado.

Um exemplo deste processo é mostrado na FIGURA 66. Nela são apresentados 13 pontos, de um lado do poste. As linhas azuis representam as diferentes soluções geradas pelo algoritmo RANSAC. A linha vermelha mostra a melhor solução.

FIGURA 66 - CIRCUNFERÊNCIAS GERADAS DURANTE O PROCESSO ITERATIVO DO RANSAC



FONTE: A autora (2016)

3.2.4.3 Análise das Componentes Principais do topo

Para analisar a forma do topo, os autovalores e autovetores dos pontos do topo foram calculados. Os autovalores ou *eigenvalues*, como são chamados, são valores obtidos a partir das matrizes de covariância ou de correlação, cujo objetivo é obter um conjunto de vetores independentes, não correlacionados, que expliquem o máximo da variabilidade dos dados. Analisar quais as variáveis ou, qual conjunto de

variáveis explica a maior parte da variabilidade total, revelando que tipo de relacionamento existe entre eles.

Os autovalores e autovetores foram calculados utilizando-se a matriz de covariância M obtida pela matriz de correlação dos elementos do topo $C(i,j)$, multiplicado pelos seus valores de desvio padrão $dp(i)$ e $dp(j)$. A correlação dos elementos faz com que as variáveis da diagonal principal da matriz de correlação C sejam iguais a 1, onde:

$$M = C(i,j) * dp(i) * dp(j) \quad (35)$$

A matriz de covariância M é uma matriz 3x3, real, positiva, o que significa que os autovalores são sempre maiores ou iguais a zero. As componentes principais são calculadas diretamente aplicando a função *eigs* do ambiente MATLAB na matriz de covariância M .


O tamanho relativo dos autovalores fornece informação para quantificar a forma tridimensional do topo. A FIGURA 67 apresenta 3 exemplos quanto a distribuição dos pontos no topo.

Se os pontos do topo estiverem bem distribuídos no espaço tridimensional, de forma regular, não haveria uma direção predominante FIGURA 67(a) e a nuvem analisada não teria correlação. O resultado seriam autovalores muito próximos.

Quando os elementos se encontram distribuídos ao longo de uma direção predominante, como no caso do cilindro na FIGURA 67(b), um dos autovalores será muito maior que os outros dois. O autovetor indicará a direção da componente principal.

Já se os pontos forem coplanares, como mostra a FIGURA 67(c), o terceiro autovalor será muito pequeno em relação aos outros dois. Portanto quando o topo dos postes e placas for analisado, os autovalores poderão auxiliar na classificação do mesmo.

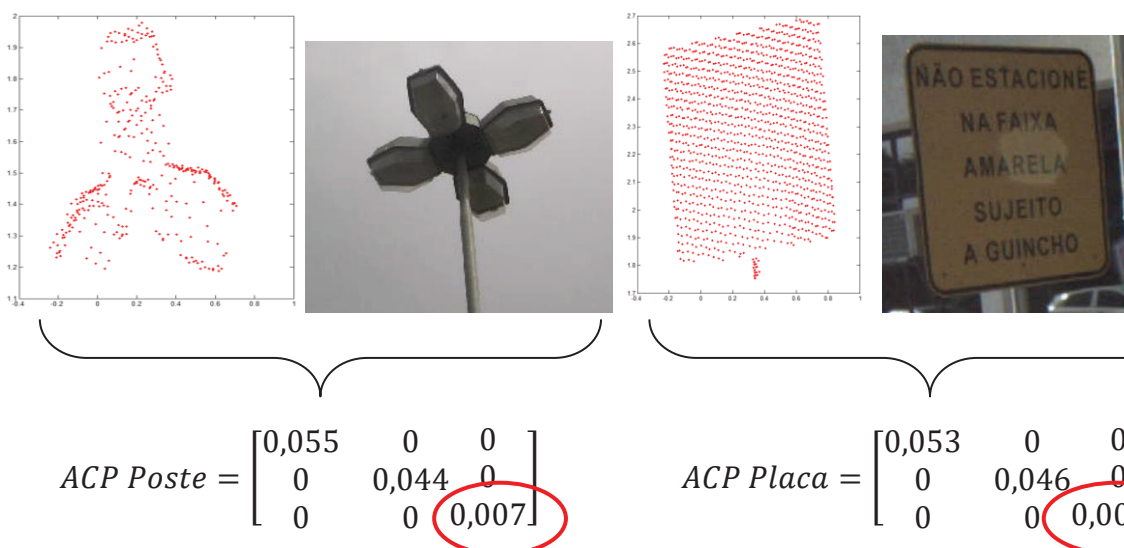
FIGURA 67 - TRÊS EXEMPLOS DE TOPO DE OBJETOS COM SEUS RESPECTIVOS VETORES.



FONTE: A autora (2016)

A FIGURA 68 apresenta o exemplo de dois tipos de elementos diferentes, no primeiro a nuvem de pontos de um poste e no segundo do topo de uma placa e suas respectivas imagens. As matrizes com os valores $\lambda_1, \lambda_2, \lambda_3$ apresentam as componentes principais e o terceiro valor circulado em vermelho mostra que os elementos têm as maiores diferenças nas componentes X e Z.

FIGURA 68 - PONTOS LASER E IMAGENS DO TOPO DE UM POSTE A DIREITA E DE UMA PLACA A ESQUERDA COM SUAS RESPECTIVAS MATRIZES COM AS COMPONENTES PRINCIPAIS



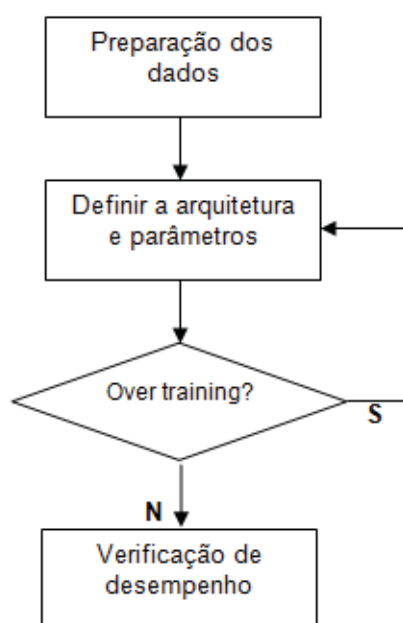
FONTE: A autora (2016)

Os valores das componentes principais dos topos dos postes e placas e o raio e altura dos suportes foram armazenados num arquivo e utilizados como a entrada da rede neural utilizada para a classificação dos postes e placas.

3.2.5 Classificação com redes neurais

Neste trabalho, as redes neurais foram criadas e manipuladas através do *Neural Network Toolbox* do Matlab®. As configurações quanto ao número de camadas escondidas, tipos de função e número de épocas do treinamento, erro final de aprendizado, taxas de treinamento e formato de saída serão apresentada neste capítulo. O desenvolvimento da criação da rede está apresentado na FIGURA 69.

FIGURA 69 - ETAPAS PARA A CRIAÇÃO DA REDE NEURAL.



FONTE: A autora (2016)

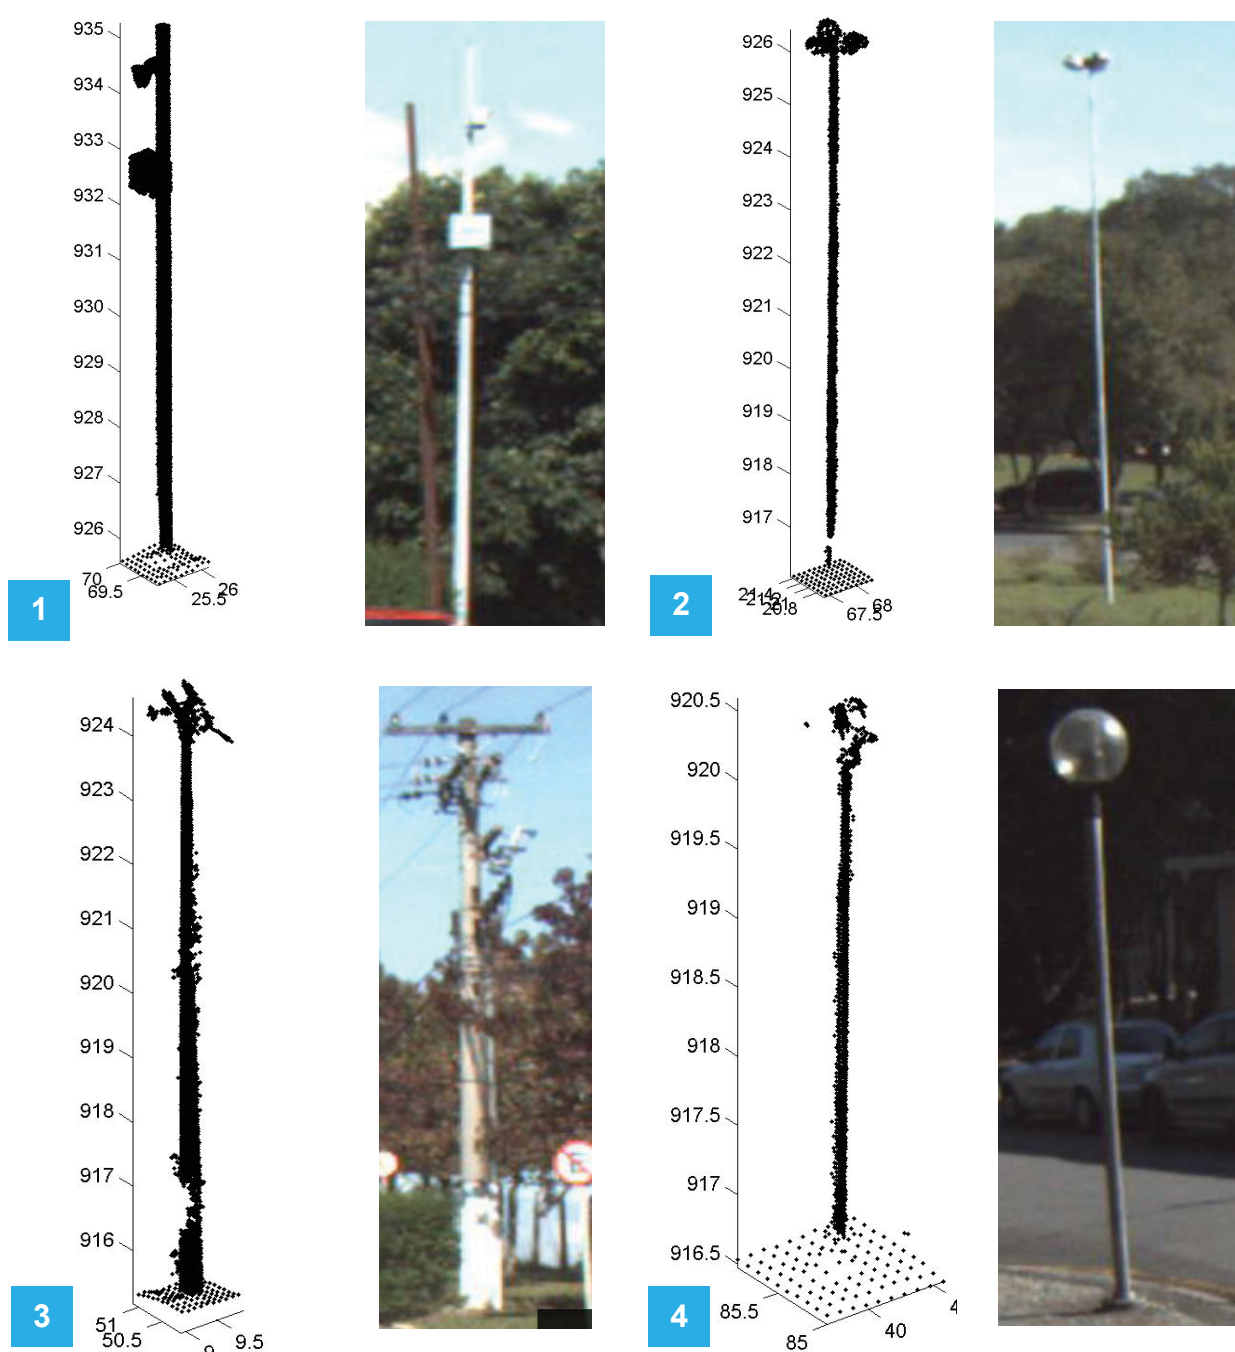
A preparação dos dados é a etapa onde os dados de entrada da rede neurais, os parâmetros de altura, raio e componentes principais, oriundos dos itens anteriores, são organizados para que a rede os interprete de maneira correta. Esses parâmetros foram armazenados inicialmente numa planilha Excel®, em arquivo único, com uma identificação numérica do elemento analisado. A planilha foi realizada para o controle dos dados de entrada e de treinamento, bem como, otimizar a necessidade de alteração do conjunto de treinamento.


Os dados de entrada são os parâmetros dos diferentes postes e placas desse estudo. Os postes e placas foram numerados sequencialmente de 1 a 7, conforme a FIGURA 70, que apresenta os 4 tipos de postes, representado nos números 1 a 4 e 4 tipos de placas, representados nos números 5 a 7.

Os parâmetros básicos necessários para a definição da arquitetura de uma rede neural são: tipo de rede e número de neurônios das camadas de entrada, intermediária ou escondida e a camada de saída. (ANDRADE,2003).


Neste sentido, o tipo de rede utilizada foi a *Feedforward* que possui o algoritmo de treinamento baseado na técnica de retropropagação, chamado de *Backpropagation*, que consiste em fazer adaptações sistemáticas nos pesos na rede, portanto recomendada para classificação supervisionada.

FIGURA 70 - TIPOS DE POSTES E PLACAS






5



6



7



FONTE: A autora (2016)

Este algoritmo escolhe valores com o objetivo de distribuir de maneira uniforme a região ativa de cada neurônio. Nessa dissertação foram utilizados os parâmetros padrões do Matlab, ou seja, uma rede com 1 camada escondida de 10 neurônios e 1 camada de saída com apenas 1 neurônio.


O algoritmo de treinamento utilizado foi o Levenberg-Marquardt, ou `trainlm` como é apresentado no Matlab®. O algoritmo de Levenberg-Marquardt foi projetado para aproximar a velocidade de treinamento de segunda ordem sem precisar

calcular a matriz de Hessian. As funções de ativação utilizadas foram a tansig, a purelin e a logsig

Para as redes com múltiplas camadas, as matrizes de peso são determinadas pelo número de camadas. É possível verificar que o peso p é igual a $R*1$ e na segunda camada é a_1 . A rede apresentada tem R como entradas, S_1 neurônios na primeira camada, S_2 neurônios na segunda camada. É comum que camadas diferentes tenham números diferentes de neurônios, conforme apresentado na FIGURA 71.

O número de neurônios da entrada (X1 a X5) foi padronizado inicialmente em 5 (altura, raio e componentes principais), 10 neurônios na camada escondida e 7 neurônios na segunda camada a camada de saída Y, conforme apresentado na FIGURA 71. A camada de saída Y1 a Y7 são os tipos de postes e placas levantados neste estudo, apresentados na FIGURA 70.

FIGURA 71 - ARQUITETURA DA REDE NEURAL



FONTE: A AUTORA (2016)

As saídas de cada camada intermediária são as entradas para a seguinte camada. Assim, a camada 2 pode ser analisada como uma rede de uma camada com entradas igual a S_1 , neurônios igual a S_2 e uma matriz de peso W_2 igual a

S2xS1. A entrada para a camada 2 é a_1 e a saída é a_2 . Com os vetores e matrizes da camada 2 é possível tratá-la como uma rede de camada única por conta própria. (DEMUTH et al, 1992)


As camadas de uma rede multicamada desempenham papéis diferentes. A camada que produz a saída de rede é chamada de camada de saída e todas as outras camadas são chamadas camadas ocultas. A rede neural apresentada possui duas camadas, uma camada de saída (camada 2) e uma camadas ocultas (camada 1). (DEMUTH et al, 1992)

O treinamento consiste em apresentar dados de entrada com seus respectivos resultados esperados. O objetivo do treinamento é minimizar o erro entre o resultado esperado e o obtido pela rede. Para garantir a diminuição desse erro, os pesos entre as ligações são ajustados a cada iteração.

Considerando que o número de dados de treinamento tenha que ser no mínimo o dobro que os neurônios de entrada, foram selecionados 32 elementos como amostra para treinamento. Esse número de dados de treinamento foi aumentado em relação ao recomendado, visto que, o Matlab® utiliza do conjunto 20% para testes, 20% para validação e 60% para treinamento.

O treinamento da rede é concluído quando o erro é menor que um limiar, ou quando é definido um número máximo de iterações. É importante evitar o excesso de treinamento, conhecido como *overfitting*, uma vez que a rede pode classificar perfeitamente os dados de treinamento, mas não funcionar com os dados de teste. (CHETTRI, CROMP e BIRMINGHAM, 1992). Na GRÁFICO 1 é apresentado o resultado de um treinamento de uma rede neural, onde o melhor desempenho na validação é o ponto onde as curvas de treinamento, validação e teste se interceptam ($mse = 0,0035$ e iteração=10).


GRÁFICO 1 - DESEMPENHO DE TREINAMENTO DA REDE



FONTE: A autora (2016)

Em conjunto com o gráfico de desempenho são analisados os gráficos de regressão. As saídas de rede são plotadas em relação aos alvos como círculos. O melhor ajuste linear é indicado por uma linha tracejada. O ajuste perfeito (saída igual a alvos) é indicado pela linha contínua. No GRÁFICO 2 estão apresentados os resultados de regressão linear.

GRÁFICO 2 - REGRESSÃO LINEAR DA REDE



FONTE: A AUTORA (2016)

Os dados foram treinados até que o melhor desempenho tenha sido atingido. Após o treinamento a rede neural foi aplicada ao conjunto total de dados.

3.3 AVALIAÇÃO DOS DADOS DE DETECÇÃO.

A avaliação da qualidade dos resultados é importante para a validação das conclusões obtidas. Neste sentido, algumas métricas de avaliação de desempenho da detecção de postes e placas serão necessárias.

A metodologia proposta para os itens apresentados anteriormente foi testada nas 18 folhas, articuladas conforme FIGURA 53, em dois conjuntos de dados, nomeados como experimento 1 e 2. O experimento 1 é o conjunto de dados que não teve nenhum tratamento antes da execução das rotinas e o experimento 2 é o conjunto de dados onde as árvores, carros e edificações foram classificados e excluídos. No experimento 2 utilizou-se também um grid regular gerado a partir da superfície do modelo digital do terreno, ambos realizados no software Terrascan®.

Com o objetivo de verificar se postes e placas foram detectados corretamente tanto a quantidade como a qualidade dos elementos, foi realizada uma checagem visual nas fotos geradas pelas 6 câmeras do sistema Pegasus One, onde serão citados como dados "reais".

Para avaliar a eficiência da detecção automática de postes e placas, a rotina de detecção foi submetida a determinados critérios de desempenho. Os critérios que foram avaliados neste item foram: precisão e sensibilidade.

A precisão é a proporção entre os itens classificados corretamente e todos os itens pertencentes à classe (EQUAÇÃO 36) e a sensibilidade mede a proporção dos classificados como verdadeiros positivos dentre todos que são realmente positivos.(EQUAÇÃO 37).

$$\text{Precisão} = \frac{\text{verdadeiros positivos (VP)}}{\text{verdadeiros positivos (VP)} + \text{falsos positivos (FP)}} \quad (36)$$

$$\text{Sensibilidade} = \frac{\text{verdadeiros positivos (VP)}}{\text{verdadeiros positivos (VP)} + \text{falsos negativos (FN)}} \quad (37)$$

A precisão e a sensibilidade também são consideradas como medidas de consistência e completude da informação. A consistência verifica se os dados foram

classificados corretamente e a completude verifica se todos os dados foram classificados.

A matriz de confusão mostra o número de classificações corretas versus as classificações desejadas sobre um conjunto de dados. Para a geração da matriz de confusão utilizou-se os dados "reais" e os dados resultantes da rotina de detecção. O quadro a seguir apresenta a matriz de confusão que será utilizada nos resultados obtidos. Os valores de VN não serão apresentados nesta dissertação.

QUADRO 3 - MATRIZ DE CONFUSÃO

		Classe Desejada	
		Verdadeiro	Falso
Classe verdadeira	Positivo	(VP) O poste/placa existe e foi detectado	(FP) O poste/placa não existe e foi detectado
	Negativo	(FN) O poste/placa existe e não foi detectado	(VN) O poste/placa não existe e não foi detectado

FONTE: A autora (2016)

4 RESULTADOS E DISCUSSÕES

Esse capítulo tem por objetivo detalhar os resultados obtidos na pesquisa. Os resultados e avaliações serão apresentados nas seguintes etapas:

- Aquisição dos dados;
- Detecção dos postes e placas
- Identificação dos postes e placas.

4.1 AQUISIÇÃO DOS DADOS

A densidade de pontos é um fator importante num levantamento laser e deve ser adequada com o objetivo do trabalho. Alguns fatores podem interferir, como a velocidade do automóvel, parametrização ou oclusões geradas por outros objetos.


O experimento 1 possui 95,25% mais pontos que o experimento 2 e consequentemente 57% mais elementos detectados. A baixa densidade de pontos pode comprometer a extração de alguma feição e a determinação de uma superfície.

Normalmente, a rua e a calçada têm uma densidade 2D moderada e todos os outros objetos que ficam afastados da trajetória da varredura têm a densidade 2D menor, por causa do alcance do sensor. Em compensação, as edificações, carros, postes possuem uma densidade 2D maior que as áreas horizontais.

O presente estudo fez uma comparação de desempenho dos resultados das rotinas de detecção de postes e placas nos dois conjuntos de dados, conforme citado anteriormente. O experimento 1 é o conjunto de dados que não teve nenhum tratamento antes da execução das rotinas e o experimento 2 é o conjunto de dados onde as árvores, carros e edificações foram classificados e excluídos. Neste sentido, os dados com tratamento prévio têm como objetivo amenizar ou solucionar os problemas de densidade causada por oclusões, antes das rotinas serem executadas.

Na FIGURA 72 apresenta-se o exemplo da folha 16, onde algumas marcas brancas indicam os lugares que não existem pontos devido às oclusões causadas pelos carros. E na imagem a direita, tem-se o detalhe de um poste que está com a parte inferior sem pontos.

FIGURA 72 - EXEMPLO DE OCLUSÃO DEVIDO AOS CARROS ESTACIONADOS E DETALHE DE UM POSTE QUE TEVE SUA BASE OMITIDA - FOLHA 16




FONTE: A autora (2016)

Percebe-se que os carros estacionados podem omitir parte do suporte da placa ou poste, bem como, comprometer a determinação do terreno por causa da falta de pontos na calçada.

As áreas com oclusão foram preenchidas a partir da geração de um grid regular oriundo do modelo digital do terreno "*ground*". A FIGURA 73 apresenta a área apresentada anteriormente após exclusão dos elementos e a geração do *grid* regular com o software TerraScan®.

FIGURA 73 - EXEMPLO DE OCLUSÃO SOLUCIONADA COM O GRID REGULAR GERADO A PARTIR DA SUPERFÍCIE DO MODELO DIGITAL DO TERRENO- FOLHA 16



FONTE: A autora (2016)

O tempo de classificação do conjunto 2 foi de 5 horas, acumulando-se classificação automática e classificação manual. A avaliação de qual conjunto de dado possui melhor desempenho dar-se-á com as rotinas que serão apresentadas nos próximos itens.

4.2 DETECÇÃO DOS POSTES E PLACAS

Os experimentos têm o objetivo de avaliar qual o conjunto de dados terá melhor desempenho na detecção do maior número de postes e placas sem e com intervenção de um processamento prévio. Foram computados os valores da quantidade de pontos e os elementos detectados por folha processada, bem como, o tempo total dos processamentos dos experimentos.

A detecção dos postes foi realizada com o Matlab® conforme citado no Capítulo 3. A rotina lê os arquivos LAS de forma iterativa, fornece um arquivo ASCII no formato xyz e uma imagem com a vista em perfil do recorte de 0,9 x 0,9 metros do elemento detectado no formato jpg.

A metodologia utilizada para detectar elementos foi a análise de densidade 2D. O limiar foi estipulado a partir da quantidade de pontos de cada folha. Todos os elementos verticais que ultrapassaram esse limiar foram selecionados.

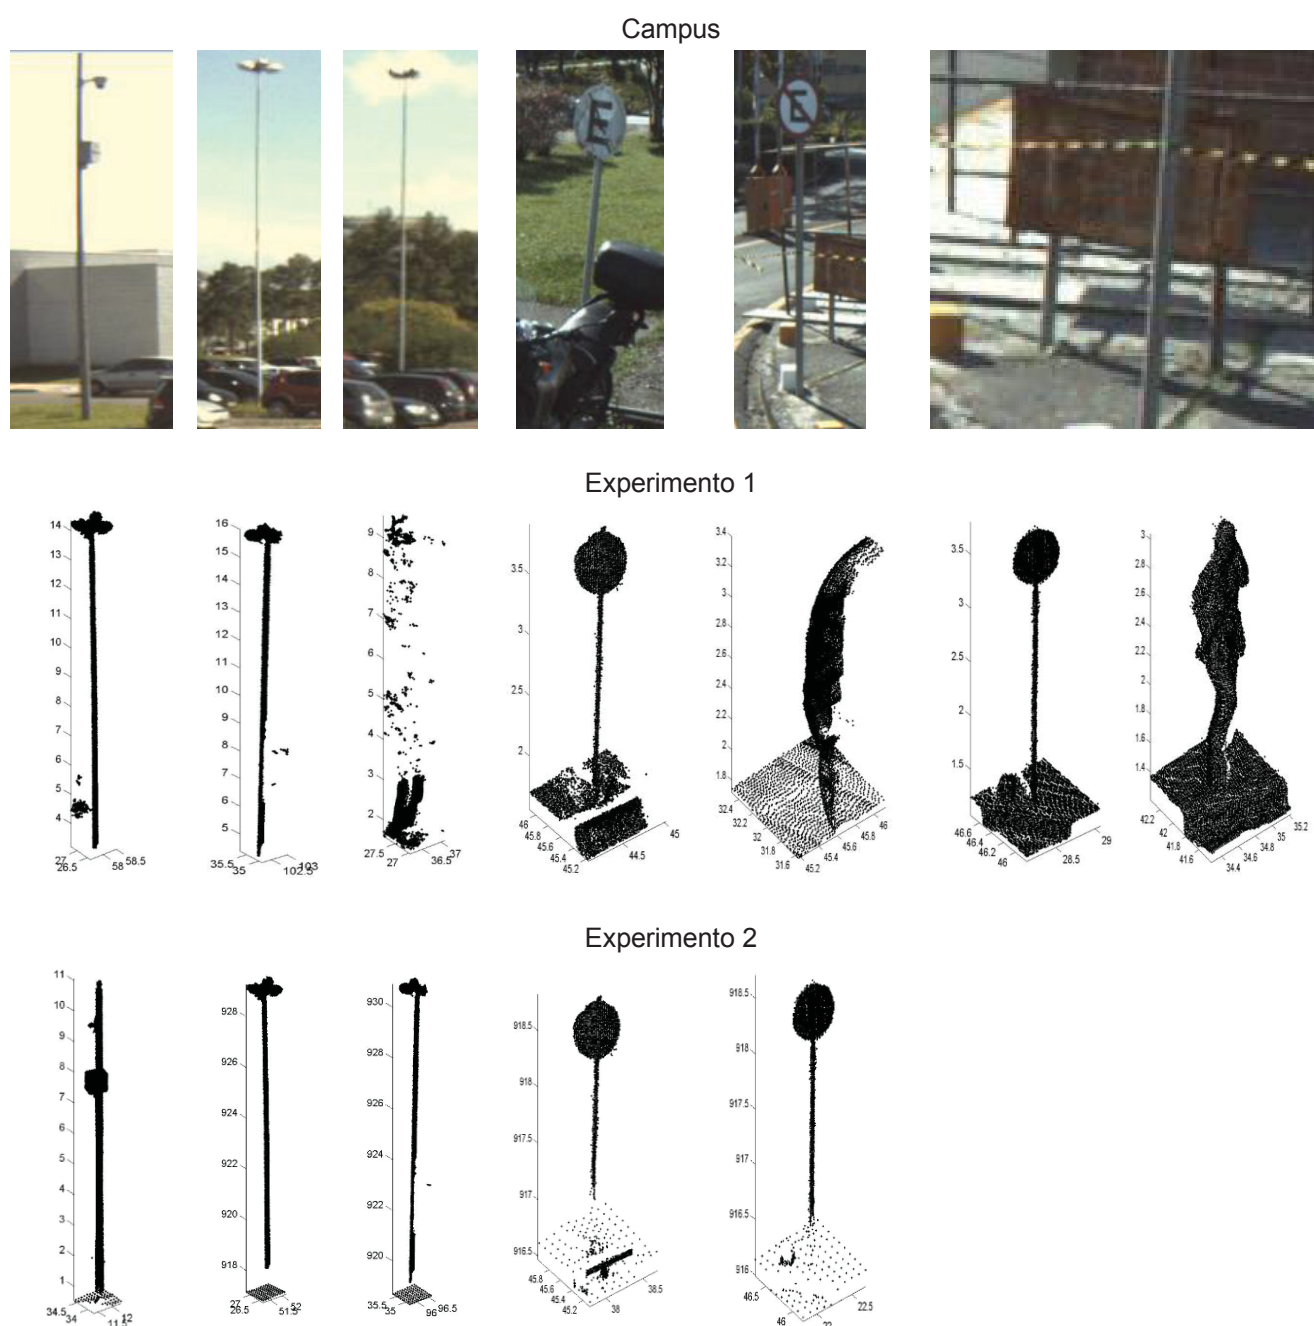
Com relação ao esforço computacional, o experimento 2 apresentou 95,2% melhor desempenho. O tempo de processamento da rotina no experimento 1 foi de 1 hora e 3 minutos e no experimento 2 foi de 3 minutos. O computador utilizado para ambos os processamentos, foi um *notebook* ASUS Intel Core i7 com 8GB de RAM e disco rígido de 350GB.

Na FIGURA 74 apresenta-se um exemplo dos elementos detectados na folha 03 para o conjunto de dados dos experimentos 1 e 2. Nota-se que no experimento 1 foram detectados 7 elementos, dos quais apenas 4 eram postes ou placas. No experimento 2 foram detectados 4 elementos e todos eram postes ou placas.

Os elementos detectados nos experimentos 1 e 2 foram disponibilizados na TABELA 1 em conjunto com a quantidade de pontos processados por folha. No segundo experimento, buscou-se reduzir o número de elementos verticais excluindo árvores, carros e edificações para otimizar o tempo de processamento da rotina sem interferir na quantidade de postes e placas detectados.

No exemplo apresentado na FIGURA 74, o experimento 1 detectou 3 elementos que não são postes ou placas. Comparando os resultados dos experimentos 1 e 2 referente a folha 3, conclui-se o experimento 2 apresentou melhor resultado, apesar da falta de detecção de 1 elemento, os elementos detectados foram postes ou placas.

FIGURA 74 - ELEMENTOS DETECTADOS NO CAMPUS E NOS EXPERIMENTOS 1 E 2 (FOLHA3).



FONTE: A autora (2016)

Na TABELA 4 apresentam-se para ambos os experimentos, as quantidades de pontos, elementos detectados pela rotina e dos elementos detectados, quantos

são postes ou placas. A coluna campus são os dados "reais", postes e placas levantadas manualmente a partir das imagens do sistema Pegasus One.

TABELA 4 - RESULTADO DA DETEÇÃO DE POSTES OBTIDO PELO EXPERIMENTO 1 E 2 E EM COMPARAÇÃO COM AS MEDIDAS "REAIS" NO CAMPUS.

Folha	Experimento 1			Experimento 2			Campus
	Quantidade de pontos	Elementos detectados	Postes Detectados	Quantidade de pontos	Elementos detectados	Postes detectados	
01	11.153.048	3	2	427.370	3	2	2
02	9.158.322	2	2	591.575	2	2	2
03	13.779.641	7	4	689.529	5	5	6
04	13.487.390	17	7	564.676	10	10	14
05	17.433.123	22	8	735.299	20	13	19
06	10.551.361	17	2	462.473	2	2	2
07	20.069.343	16	6	883.957	9	9	10
08	11.731.878	19	3	868.497	6	6	8
09	14.012.008	12	3	417.325	16	16	17
10	8.490.727	13	7	431.082	20	18	24
11	6.012.773	18	7	219.164	9	8	11
12	9.907.722	10	5	364.188	12	10	13
13	10.761.527	20	13	755.694	17	15	15
14	7.145.310	8	5	414.302	14	13	13
15	15.756.254	16	9	479.886	15	13	15
16	5.770.124	7	3	211.535	19	12	12
17	9.376.580	12	8	320.906	23	10	11
18	11.389.435	22	8	934.534	15	14	16
Total	205.986.566	241	102	9.771.992	278	178	210

FONTE: A autora (2016)

Foi elaborada a matriz de confusão para os experimentos 1 e 2 e consequentemente calculados os resultados de precisão e sensibilidade.

Optou-se em utilizar o conjunto de dados do experimento 2 para a classificação dos postes e placas pela rede neural por apresentar melhores resultados. O número de elementos detectados pelo experimento 2 foi 57,30% maior. Os resultados de precisão e sensibilidade também apresentaram melhor desempenho.

TABELA 5 - MATRIZ DE CONFUSÃO DOS ELEMENTOS DETECTADOS NO EXPERIMENTO 1

Classe	Desejada			
	Verdadeiro Experimento1	Falso Experimento 1	Verdadeiro Experimento2	Falso Experimento 2
Verdadeira Positiva	102	139	178	32
Verdadeira Negativa	108		100	

FONTE: A autora (2016)

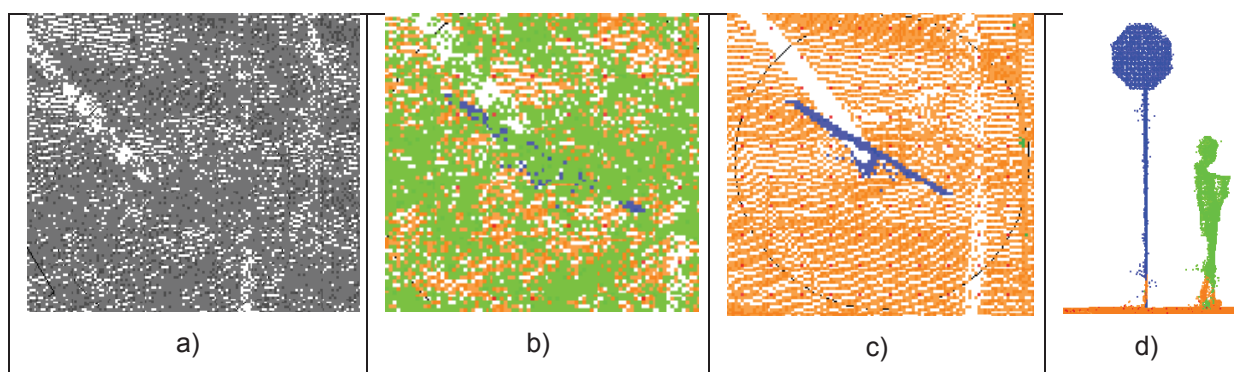
TABELA 6 - RESULTADOS DE PRECISÃO, SENSIBILIDADE DOS EXPERIMENTOS.

Objetos	Precisão	Sensibilidade
Experimento 1	42,32%	48,57%
Experimento 2	84,76%	64,02%

FONTE: A autora (2016)

Apesar de serem elementos visivelmente bem perceptíveis, a representação dos postes e placas numa nuvem de pontos é complexa. Para a detecção automática, o tratamento prévio dos dados auxiliou o processamento da rotina, bem como a verificação dos dados processados. A FIGURA 75 apresenta um mesmo recorte com várias formas de representação diferentes: sem classificação (a), com classificação (b), sem as árvores (c) e em vista de perfil (d).

FIGURA 75 - ELEMENTO POSTE TIPO 4 APRESENTADO DE FORMAS DIFERENTES.

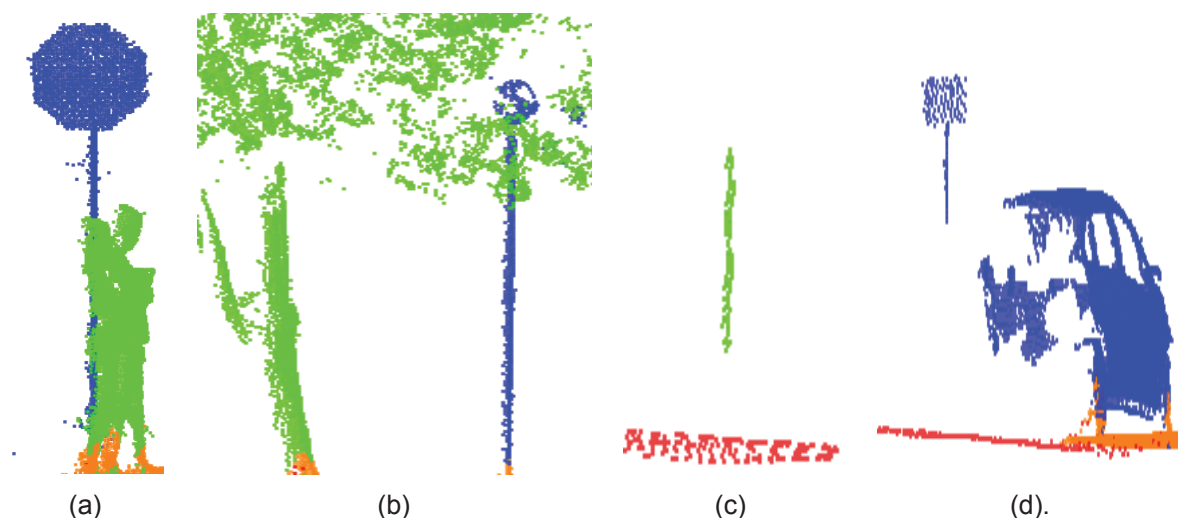


FONTE: A autora (2016)

Percebe-se que qualquer outro elemento que esteja próximo pode comprometer o resultado da detecção ou classificação. Durante o processamento foram detectados alguns postes ou placas com problemas, que podem não ser identificados corretamente posteriormente pela rede neural. Na FIGURA 76 tem alguns exemplos de problemas encontrados. Muitos desses problemas estão

intrínsecos à metodologia, portanto quando encontrados esses elementos são retirados manualmente, conforme exemplo apresentado na FIGURA 76, que apresenta: a) placa com uma pessoa ao lado, b) postes debaixo de árvore; c) elemento incompleto e d) placas com falhas.

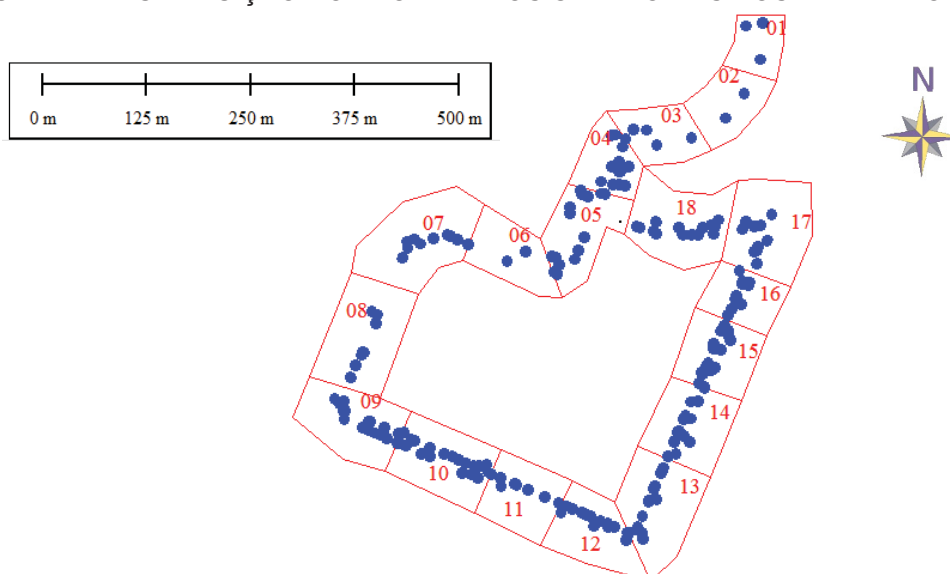
FIGURA 76 - ELEMENTOS DETECTADOS COM POSSÍVEIS PROBLEMAS PARA A REDE NEURAL.



FONTE: A autora (2016)

Após todos os elementos terem sido detectados foi possível verificar a espacialização dos mesmos. Com isso, perceber se onde estão as áreas com a maior e menor quantidade de postes e placas. (FIGURA 77).

FIGURA 77 - DISTRIBUIÇÃO HORIZONTAL DOS CENTROIDES DOS ELEMENTOS DETECTADOS



FONTE: A autora (2016)

4.3 IDENTIFICAÇÃO DOS ELEMENTOS DETECTADOS

4.3.1 Coleta e preparo dos dados


Os centroides dos elementos detectados estão apresentados por folha no ANEXO 2 e representam a distribuição espacial, bem como, a quantidade de elementos detectados naquele segmento. No total foram detectados 278 elementos em 18 folhas, porém foram utilizados apenas 220 para a classificação devido aos elementos duplicados.

Como citado anteriormente, os elementos detectados foram recortados em arquivos individuais e salvos no formato ASCII (txt) e imagem raster (jpg). A rotina de análise utilizou as informações dos arquivos ASCII para calcular os parâmetros que a RNA utilizou para identificar que tipo de elemento foi detectado.

Os elementos duplicados ocorreram por causa da proximidade dos elementos verticais. Todos os elementos verticais potenciais postes ou placas que foram considerados como potenciais, foram recortados a cada 1 metro, portanto alguns elementos poderia pertencer ao mesmo recorte e se o limiar fosse alterado, outros elementos não seriam detectados na sua completude.

A determinação dos limiares foi uma etapa complexa, pois os elementos são pequenos se comparados com a área e possuem características bem distintas. A FIGURA 78 apresenta um exemplo onde a distância entre o poste e a placa é de 60 cm e parte do elemento ficou nos dois arquivos.


FIGURA 78 - ELEMENTOS VERTICAIS PRÓXIMOS QUE NA DETECÇÃO FICARAM DUPLICADOS



FONTE: A autora (2016)

A classificação deu-se em 7 classes, conforme apresentada na FIGURA 70 no Capítulo 3. A classe 8 trata-se de elementos verticais que o suporte foi detectado, mas que não é possível identificar se é um poste ou uma placa. A distribuição e a quantidade de elemento das classes estão apresentadas no GRÁFICO 3, onde este resultado é oriundo da verificação visual dos elementos pelas imagens geradas pela rotina de detecção.

GRÁFICO 3 - QUANTIDADE DE ELEMENTOS POR CLASSE



FONTE: A autora (2016)

Observou-se que os postes de regulamentação redondos representam 33% do total de elementos detectados, bem como, que a classe 4, as luminárias de iluminação interna, representam 27%. Esses percentuais definem que esses tipos representam 60% de todo o campus e por este motivo serão destinadas mais amostras de treinamento para essas duas classes.

4.3.2 Criação da RNA


Para o desenvolvimento da RNA, utilizou-se a biblioteca *Neural Network Toolbox do Matlab (2013)*. A utilização de uma RNA inicia-se na escolha da arquitetura em que os neurônios serão organizados e a fase de aprendizagem.

Utilizou-se o algoritmo de aprendizado supervisionado *Backpropagation*. A maioria dos métodos de aprendizado utilizam variações deste algoritmo, por isso é o processo supervisionado mais conhecido e utilizado para treinamento de redes neurais multicamadas.

A definição dos parâmetros desse algoritmo é um processo complexo, pois ele ajusta os pesos e limiares a partir dos erros dos nodos das camadas intermediárias por um método gradiente. Esse método nem sempre converge corretamente, por isso essa etapa é importante no treinamento.

Para o treinamento, dos 220 elementos detectados, definiu-se 15% como amostra para treinamento. O GRÁFICO 4 apresenta a quantidade de elementos de cada classe que foi utilizada para treinamento, bem como, o percentual representativo de cada classe. A classe 8 refere-se a elementos que possuem um suporte, mas não são identificados como postes ou placas.

GRÁFICO 4 - QUANTIDADE E PORCENTAGEM DOS 38 ELEMENTOS PARA TREINAMENTO POR CLASSE



FONTE: A autora (2016)

Os elementos selecionados para a RNA *Backpropagation*, contém as informações de altura, raio e componentes principais. Procedeu-se a partir desses dados os testes de treinamento da rede neural.

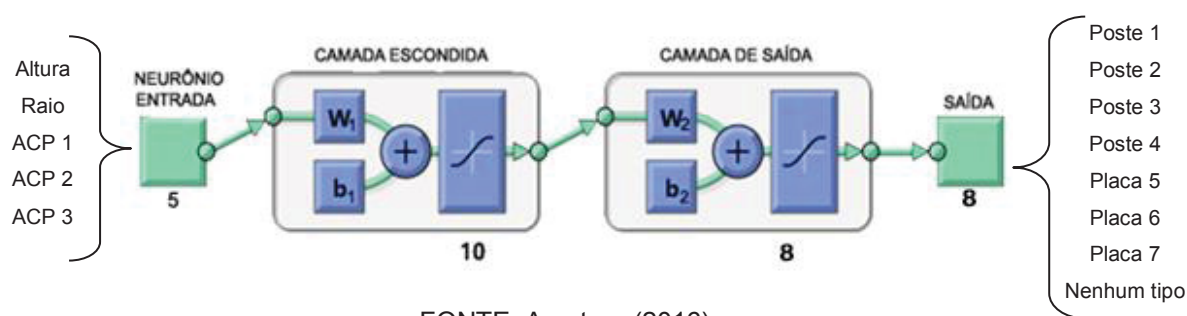
Conforme citado na metodologia, utilizou-se a função de treinamento *TRAINLM*, que utiliza o algoritmo *Levenberg-Marquardt*. Esse algoritmo é projetado para problemas de mínimos quadrados que são aproximadamente lineares. É a função com o menor tempo de convergência e utilizada como padrão pelo Matlab.

As funções de ativação tem a função de limitar a amplitude do sinal de saída do neurônio. Realizaram-se testes de desempenho com as funções sigmoidal, linear e tangente hiperbólica, disponibilizadas no Matlab como *LOGSIG*, *PURELIN* E *TANSIG* respectivamente.

4.3.3 Treinamento, validação e aplicação da RNA.

A arquitetura da RNA utilizada para o treinamento está apresentada na FIGURA 79, onde a camada de entrada foram os valores das variáveis das 38 amostras de treinamento e a camada de saída são dividida em 8 classes, 7 tipos de postes e placas classificados e a uma classe destinada aos elementos verticais que possuem apenas o suporte, mas que não é possível identificar se é um poste ou placa.

FIGURA 79 - ARQUITETURA DA RNA.




FONTE: A autora (2016)



Os dados de treinamento são divididos automaticamente como 70% para o conjunto de treinamento, 15% para validação e 15% para teste. Portanto ficaram 27 elementos para treinamento, 5 para validação e 6 para teste. O erro no conjunto de validação é monitorado durante o treinamento e quando a validação aumenta o treinamento é interrompido.

Inicialmente, os pesos e limiares foram inicializados conforme recomendação do manual (Beable et al, 2011). Alterou-se a função de ativação para testar qual teria melhor resultado e todos os outros parâmetros foram utilizados conforme padrão do Matlab. Durante o treinamento, o progresso foi constantemente atualizado na janela de treinamento.

Após algumas iterações as RNA's convergiram. Verificou-se a posição da curva de teste e se a mesma aumentasse significativamente antes da curva de validação, o problema de overfitting poderia ter ocorrido. Os resultados estão apresentados conforme o GRÁFICO 5 com as 3 funções de ativação.

GRÁFICO 5 - DESEMPENHO DA VALIDAÇÃO QUANTO A FUNÇÃO DE ATIVAÇÃO



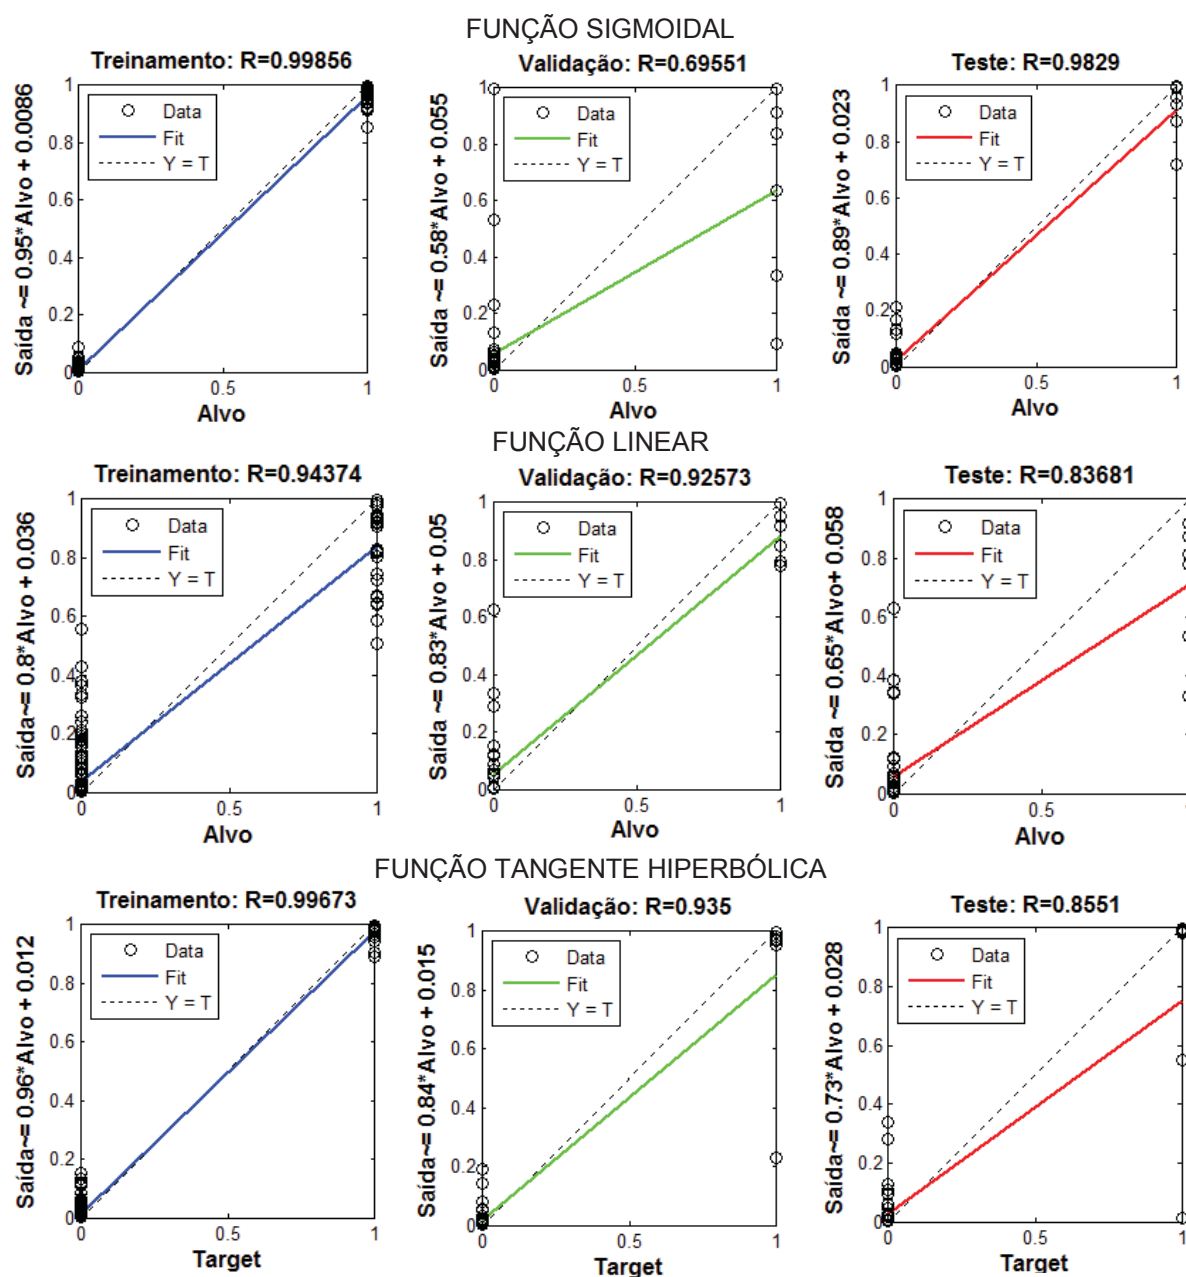


FONTE: A autora (2016)

O gráfico de regressão mostra a relação entre as saídas da RNA comparando com o alvo nos conjuntos de treinamento, validação e teste. Os

resultados estão apresentados no GRÁFICO 6. A função que apresentou melhor resultado foi a tangente hiperbólica (*TANSIG*).

GRÁFICO 6 - REGRESSÃO QUANTO A FUNÇÃO DE ATIVAÇÃO



FONTE: A autora (2016)

A partir desses resultados, optou-se utilizar a função tangente hiperbólica que obteve o melhor resultado para aplicar nos dados. Dos 220 elementos, 27 não foram classificados corretamente, ou seja, 87,73% de acerto global. A TABELA 7 apresenta a matriz de confusão com a média das porcentagens do resultado da RNA escolhida aplicada nos elementos. A diagonal principal trata-se dos resultados

de cada uma das classes. A partir desta, conclui-se que os elementos do tipo 1,2 e 6 apresentaram os piores resultados com 52,99%, 50,40% e 31,56% respectivamente.

TABELA 7 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS DAS CLASSES EM 100% DO CONJUNTO DE 220 ELEMENTOS.

TIPO	1	2	3	4	5	6	7	8
1	63.09%	15.52%	0.58%	6.04%	0.01%	6.91%	0.19%	0.01%
2	30.22%	50.40%	0.00%	23.06%	0.00%	9.00%	0.00%	0.03%
3	1.03%	0.01%	91.58%	1.19%	0.00%	0.40%	0.50%	0.04%
4	1.96%	0.20%	0.00%	96.76%	2.78%	0.77%	0.00%	0.09%
5	0.37%	0.00%	0.67%	4.39%	92.15%	2.66%	4.22%	0.14%
6	10.38%	5.61%	0.50%	2.04%	44.95%	31.56%	16.90%	0.26%
7	0.04%	0.00%	0.85%	0.07%	20.60%	13.99%	69.66%	0.11%
8	0.29%	2.50%	0.02%	0.59%	0.88%	0.05%	0.00%	97.56%

FONTE: A autora (2016)

Na TABELA 8 apresentam-se as quantidades por classe onde o elemento do tipo 6 apresenta o pior resultado. Dos 18 elementos, apenas 4 foram classificados corretamente.

TABELA 8 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE EM 100% DO CONJUNTO DE 220 ELEMENTOS.

TIPO	1	2	3	4	5	6	7	8	TOTAL
1	4	1	0	1	0	0	0	0	6
2	3	2	0	0	0	0	0	0	5
3	0	0	10	0	0	0	0	0	10
4	2	0	0	58	0	0	0	0	60
5	0	0	0	4	66	1	1	0	72
6	2	1	0	1	7	4	3	0	18
7	0	0	0	0	2	0	6	0	8
8	1	0	0	0	0	0	0	40	41
TOTAL	12	4	10	64	75	5	10	40	220

FONTE: A autora (2016)

Enfim a TABELA 9 apresenta os resultados finais de precisão e sensibilidade. Pelo baixo desempenho na classificação dos elementos dos tipos 1,2 e 6, foram analisadas individualmente as amostras para identificar qual variável é mais relevante e quais amostras apresentavam algum problema.

TABELA 9 - RESULTADO DE PRECISÃO E SENSIBILIDADE DO CONJUNTO DE 220 ELEMENTOS

TIPO	VP	FN	FP	TOTAL	PRECISÃO	SENSIBILIDADE
1	4	2	8	6	33.33%	66.67%
2	2	3	6	5	50.00%	40.00%
3	10	0	0	10	100.00%	100.00%
4	58	2	6	60	90.63%	96.67%
5	66	6	9	72	88.00%	91.67%
6	4	14	1	18	80.00%	22.22%
7	6	2	4	8	60.00%	75.00%
8	40	1	0	41	100.00%	97.56%

FONTE: A autora (2016)


Deu-se início as análises das variáveis referentes ao topo e ao suporte dos 220 elementos. As variáveis do topo são as 3 componentes principais e as variáveis do suporte são a altura e o raio.

Verificando os elementos que não foram classificados corretamente, notou-se que os elementos do tipo 1 possuem alturas diferentes dentro da mesma classe, devido a oclusão por algum objetos, e que os elementos do tipo 6 possuem os valores das componentes principais bem parecidas com os elementos do tipo 7. Portanto, conclui-se que os problemas ocorreram por interferência das variáveis tanto do topo como do suporte.

A FIGURA 80 apresenta os números e as imagens de alguns exemplos de elementos que não foram classificados corretamente. A maior parte é formada por postes e placas incompletas ou com ruídos. Com o objetivo de obter um conjunto de dados com o máximo de acertos possível, foram excluídos 28 elementos que tinham problemas de estrutura ou ruídos, 40 elementos que não eram postes ou placas e incluídos 2 elementos no conjunto de treinamento.

Como pode ser visto, alguns elementos são difíceis de serem distinguidos visualmente, sendo exemplos os elementos 3 e 75. Alguns são bem identificáveis, porém as variáveis são parecidas com elementos de outra classe e a RNA não consegue diferenciar com eficiência.

FIGURA 80 - EXEMPLOS DE ALGUNS ELEMENTOS QUE NAO FORAM CLASSIFICADOS CORRETAMENTE




FONTE: A autora (2016)

Com o objetivo de comprovar a eficiência da RNA, foram retirados os elementos que não tinham o topo e elementos incompletos para uma nova análise. O novo conjunto de dados ficou então com 152 elementos e o conjunto de treinamento com 40 elementos.

O novo conjunto de treinamento representa 26% do total de elementos selecionados para estudo e está apresentado no GRÁFICO 7 . Este gráfico apresenta a quantidade de elementos de cada classe que foi utilizada para treinamento, bem como, o percentual representativo de cada classe. O treinamento foi realizado com a função tangente hiperbólica *transig* utilizada no experimento anterior.

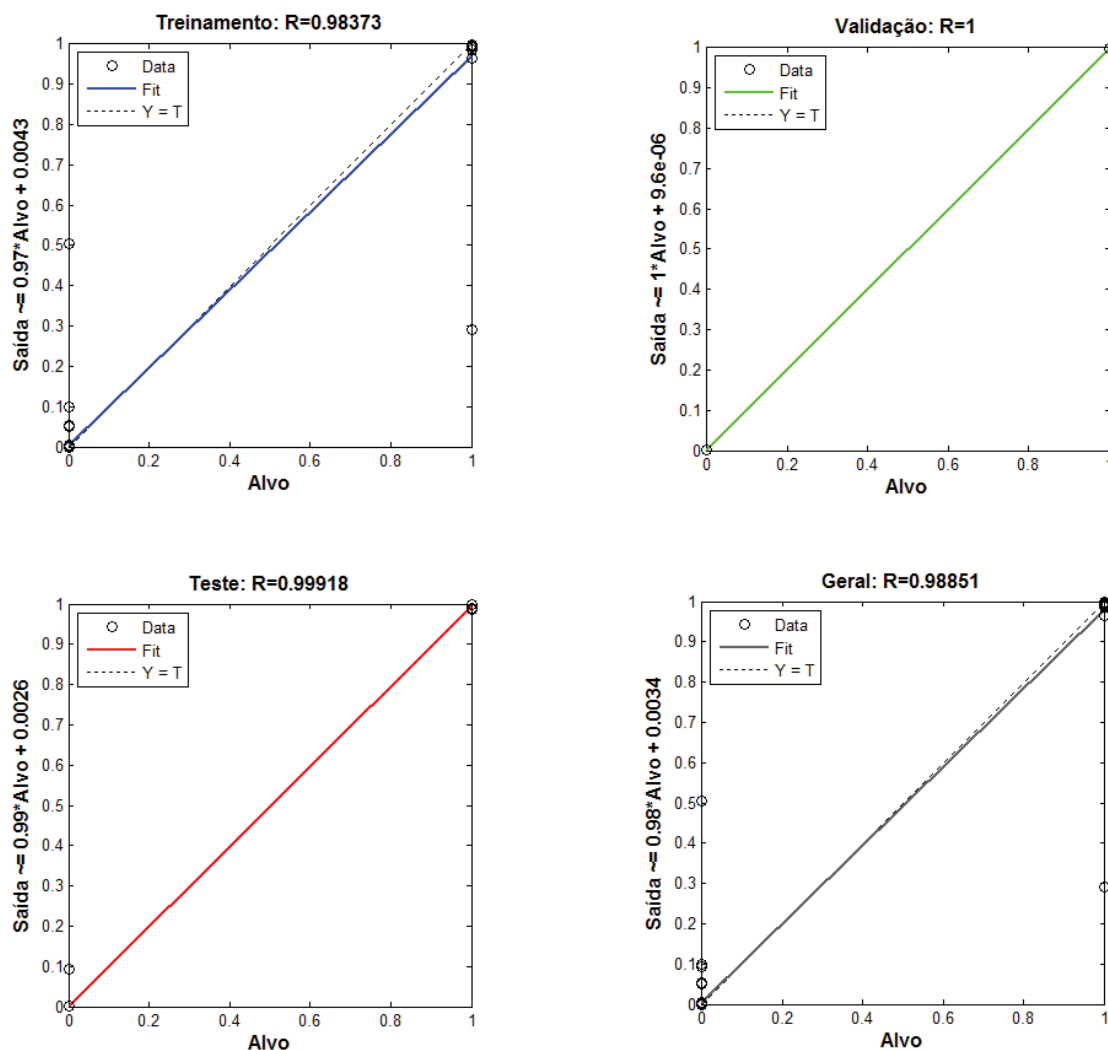
GRÁFICO 7 - QUANTIDADE E PORCENTAGEM DOS 40 ELEMENTOS PARA TREINAMENTO POR CLASSE.



FONTE: A autora (2016)

A rede neural convergiu depois de 17 iterações. O GRÁFICO 8 apresenta o resultado do treinamento, que ficou no geral com 98,02% de acertos. Este gráfico apresenta as melhores estimativas para o conjunto de dados.

GRÁFICO 8 - GRÁFICO DE REGRESSÃO DO TREINAMENTO DOS 152 ELEMENTOS COM TODAS AS VARIÁVEIS.



FONTE: A autora (2016)

Após o treinamento a rede foi testada no conjunto de 152 elementos. O resultado foi de 98,68% de acerto. Apenas 1 placa do tipo 7 e 1 poste do tipo 3 não foram classificadas corretamente. A matriz de confusão das médias percentuais de acerto está apresentada na TABELA 10, onde é possível verificar que os elementos do tipo 3 e 7 apresentaram as maiores variações visualizando os dados da diagonal principal e o poste do tipo 7 apresentou o pior resultado 86,10% comparando com os outros tipos.

TABELA 10 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS POR CLASSE EM 100% DO CONJUNTO DE 152 ELEMENTOS COM TODAS AS VARIÁVEIS.

TIPO	1	2	3	4	5	6	7
1	100.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
2	0.00%	100.00%	0.01%	0.00%	0.01%	0.00%	0.01%
3	0.02%	0.01%	90.12%	0.00%	0.00%	0.03%	7.96%
4	0.00%	0.00%	0.00%	98.30%	2.63%	7.41%	0.00%
5	0.00%	0.00%	0.00%	0.00%	99.72%	0.00%	2.57%
6	0.00%	0.00%	0.02%	0.00%	1.25%	99.80%	0.00%
7	0.00%	0.00%	0.00%	0.00%	0.01%	17.04%	86.10%

FONTE: A autora (2016)

Na TABELA 11, comprova-se o resultado satisfatório em todas as classes, bem como, o poste do tipo 3 que foi classificado como tipo 7 e a placa do tipo 7 que foi classificada como tipo 6. A RNA gerada a partir desse conjunto de dados de treinamento foi utilizada posteriormente para analisar a relevância das variáveis.

TABELA 11 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE EM 100% DO CONJUNTO DE 152 ELEMENTOS COM TODAS AS VARIÁVEIS.

TIPO	1	2	3	4	5	6	7	TOTAL
1	2	0	0	0	0	0	0	2
2	0	1	0	0	0	0	0	1
3	0	0	9	0	0	0	1	10
4	0	0	0	56	1	0	0	57
5	0	0	0	0	68	0	0	68
6	0	0	0	0	0	8	0	8
7	0	0	0	0	0	1	5	6
TOTAL	2	1	9	56	69	9	6	152

FONTE: A autora (2016)

Apesar da RNA apresentar um bom resultado, ele não reflete a realidade porque os elementos duvidosos foram deixados fora desse estudo. Porém, dessa forma foi possível fazer a análise de qual variável teve maior relevância na RNA.

A TABELA 12 apresenta os resultados de precisão e sensibilidade, onde as placas do tipo 6 e 7 apresentam 1 elemento falso positivo cada, diminuindo a sensibilidade para 88,89% e 83,33% respectivamente e a precisão da placa de tipo 7 para 83,33%.

TABELA 12 - RESULTADO DE PRECISÃO, SENSIBILIDADE E ACURACIDADE DO CONJUNTO DE 152 ELEMENTOS COM TODAS AS VARIÁVEIS.

TIPO	VP	FN	FP	TOTAL	PRECISÃO	SENSIBILIDADE
1	2	0	0	2	100.00%	100.00%
2	1	0	0	1	100.00%	100.00%
3	9	1	0	10	90.00%	100.00%
4	57	0	0	57	100.00%	100.00%
5	68	0	0	68	100.00%	100.00%
6	8	0	1	8	100.00%	88.89%
7	5	1	1	6	83.33%	83.33%

FONTE: A autora (2016)

Percebeu-se que o poste tipo 3 que não foi classificado corretamente possui o valor de altura diferente dos outros postes da mesma classe e as placas do tipo 7 que foram classificadas como tipo 6 possuem valores das componentes principais muito próximos. Portanto a análise das variáveis é pertinente e determinará qual variável é mais sensível na classificação.

Inicialmente a análise foi realizada aplicando a mesma rede neural já treinada num conjunto de dados com as variáveis de altura e raio e a média da variável das componentes principais. A resultado geral foi de 61,05% e 81 elementos não foram classificados corretamente.

Os resultados foram apresentados nas TABELA 13, TABELA 14 e TABELA 15. Notou-se que apenas os elementos dos tipos 1 e 5 conseguiram bons resultados 99,99% e 99,97%, concluindo que apenas com a variável altura e raio não seria possível classificar os postes e placas desse levantamento.

Nota-se que a classificação dos postes dos tipos 1, 2 e 3 que possuem alturas semelhantes foram classificados como tipo1 e os postes do tipo 4 foram classificados como placa do tipo 5. A confusão é compreendida pelo fato de que os elementos possuem alturas e raios semelhantes.

TABELA 13 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS CONSIDERANDO APENAS ALTURA E RAIO.

TIPO	1	2	3	4	5	6	7
1	99.99%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
2	86.92%	0.00%	0.00%	25.40%	0.00%	0.00%	0.11%
3	90.21%	0.00%	0.00%	0.00%	0.00%	0.03%	0.00%
4	0.00%	0.00%	0.00%	1.83%	95.56%	0.00%	0.00%
5	0.00%	0.00%	0.00%	0.01%	99.97%	0.55%	0.00%
6	0.00%	0.00%	0.00%	0.00%	97.68%	3.07%	0.00%
7	0.00%	0.00%	0.00%	0.00%	99.46%	0.32%	0.00%

FONTE: A autora (2016)

Destaca-se na TABELA 14 pela quantidade de elementos classificados por classe, que em alguns tipos nenhum elemento foi classificado, como exemplo, os tipos 2, 3, 6 e 7, mostrando a relevância das componentes principais na RNA desses elementos.

TABELA 14 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE CONSIDERANDO APENAS ALTURA E RAIO.

TIPO	1	2	3	4	5	6	7	TOTAL
1	2	0	0	0	0	0	0	2
2	1	0	0	0	0	0	0	1
3	9	0	0	0	0	0	1	10
4	0	0	0	1	56	0	0	57
5	0	0	0	0	68	0	0	68
6	0	0	0	0	8	0	0	8
7	0	0	0	0	6	0	0	6
TOTAL	12	0	0	1	138	0	1	152

FONTE: A autora (2016).

Em contrapartida, os elementos dos tipos 1 e 5 foram classificados corretamente, apresentando 100% de precisão conforme apresentado na TABELA 15. A quantidade de falsos positivos nessas duas classes fez com que a sensibilidade fosse bem baixa 16,67% e 49,28% respectivamente.

TABELA 15 - RESULTADO DE PRECISÃO E SENSIBILIDADE CONSIDERANDO APENAS ALTURA E RAIO.

TIPO	VP	FN	FP	TOTAL	PRECISÃO	SENSIBILIDADE
1	2	0	10	2	100.00%	16.67%
2	0	1	0	1	0.00%	0.00%
3	0	10	0	10	0.00%	0.00%
4	1	56	0	57	1.75%	100.00%
5	68	0	70	68	100.00%	49.28%
6	0	8	0	8	0.00%	0.00%
7	0	6	1	6	0.00%	0.00%

FONTE: A autora (2016).

Considerando somente as variáveis das componentes principais e mantendo a média dos valores de altura e raio, percebeu-se a partir da TABELA 16 e TABELA 17 que os elementos dos tipos 1 e 3 não tiveram nenhum elemento classificado corretamente. Isso deve-se a semelhança dos valores de topo desses elementos.

TABELA 16 - MATRIZ DE CONFUSÃO DAS MÉDIAS DOS RESULTADOS PERCENTUAIS CONSIDERANDO APENAS COMPONENTES PRINCIPAIS.

TIPO	1	2	3	4	5	6	7
1	0.00%	0.00%	0.00%	50.00%	50.00%	0.02%	0.00%
2	0.00%	98.89%	1.05%	0.00%	99.96%	15.75%	99.12%
3	0.00%	0.83%	0.01%	0.00%	76.92%	2.16%	52.76%
4	0.00%	0.00%	0.00%	97.15%	2.07%	14.00%	0.00%
5	0.00%	0.00%	0.00%	0.05%	96.59%	0.01%	4.93%
6	0.00%	0.00%	0.04%	0.00%	9.40%	78.39%	0.09%
7	0.00%	0.00%	0.00%	0.00%	0.00%	0.35%	92.37%

FONTE: A autora (2016)

TABELA 17 - MATRIZ DE CONFUSÃO DA QUANTIDADE DE ELEMENTOS POR CLASSE CONSIDERANDO APENAS COMPONENTES PRINCIPAIS.

TIPO	1	2	3	4	5	6	7	TOTAL
1	0	0	0	1	1	0	0	2
2	0	1	0	0	0	0	0	1
3	0	0	0	0	9	1	0	10
4	0	0	0	56	1	0	0	57
5	0	0	0	0	66	0	2	68
6	0	0	0	0	1	7	0	8
7	0	0	0	0	0	0	6	6
TOTAL	0	0	0	1	1	0	0	152

FONTE: A autora (2016)

Os elementos dos tipos 2, 4 e 5 apresentaram o resultado de 100%, 98,25% e 97,06% respectivamente, indicando uma boa precisão. Porém apresentaram um número significativo de falsos positivos e falsos negativos, conforme apresentado na TABELA 18.

TABELA 18 - RESULTADO DE PRECISÃO E SENSIBILIDADE CONSIDERANDO APENAS COMPONENTES PRINCIPAIS.

TIPO	VP	FP	FN	TOTAL	PRECISÃO	SENSIBILIDADE
1	0	2	0	2	0.00%	0.00%
2	1	0	0	1	100.00%	100.00%
3	0	10	0	10	0.00%	0.00%
4	56	1	1	57	98.25%	98.25%
5	66	2	12	68	97.06%	84.62%
6	7	1	1	8	87.50%	87.50%
7	6	0	2	6	100.00%	75.00%

FONTE: A autora (2016)

Neste sentido, comparando as análises realizadas é possível concluir que o resultado da classificação considerando apenas altura e raio apresentou um resultado inferior ao das componentes principais (que descrevem a forma do elemento do topo: placa ou luminária). Portanto o uso das componentes principais em conjunto com as variáveis de altura e raio do objeto é relevante e apresenta uma melhora significativa na classificação dos objetos.

5 CONCLUSÕES

Durante o desenvolvimento dessa pesquisa, foram apresentadas todas as etapas desde o levantamento a *laser* com um sistema móvel terrestre até a classificação do objeto poste ou placa obtido pelo mesmo. Através de algumas rotinas, foi possível a partir de uma nuvem de pontos separar elementos com dimensões e formas geométricas distintas e classificá-lo quanto ao seu tipo automaticamente.

Apesar de a área de estudo ser um cenário urbano e dos objetos em questão serem visualmente bem identificáveis para a detecção, matematicamente não foi uma tarefa simples. Notou-se que as árvores, carros e até pedestres encontrados ao longo do percurso obstruíram alguns objetos, necessitando assim, um refinamento de alguns parâmetros das rotinas, ou quando muito complexos, sua exclusão. Em virtude dos fatos mencionados, é recomendado realizar o perfilamento em um dia e horário que não tenha muitos carros estacionados ou pedestres no percurso.

No processamento dos dados, o passo inicial é a detecção dos postes e placas, elementos verticais, por meio de segmentação. A segmentação utilizada é baseada na análise da densidade 2D e depende de um limiar de concentração de pontos. Percebe-se que o método depende em extremo deste limiar que, se usado de forma incorreta, pode fazer com que o método deixe de detectar objetos que interessam ou detectar muitos objetos que não interessam como foi visto nos experimentos apresentados. Os postes e placas localizados longe da trajetória, por exemplo, apresentaram uma densidade muito menor de pontos, ocorrendo assim, a não detecção desses objetos. Resultados mais consistentes serão obtidos se o levantamento for mais uniforme em termos de densidade de pontos na superfície dos objetos.

A análise dos objetos se baseia em inicialmente separar o objeto detectado em duas partes: topo e suporte. Isto proporcionou o cálculo das variáveis necessárias para a classificação, com baixo custo computacional, podendo assim, os limiares das rotinas serem ajustados conforme o resultado obtido. Foi observado que é possível separar o topo analisando a densidade de pontos ao longo da vertical. A forma do suporte foi descrita em termos de altura e raio do objeto. Já a

forma do topo foi descrita com ajuda da análise das componentes principais da nuvem de pontos 3D.

Os dados derivados da nuvem de pontos foram usados como entrada no processo de classificação usando redes neurais artificiais. Foram realizados alguns experimentos com o objetivo de avaliar a eficiência da metodologia empregada. Conclui-se que as variáveis de altura, raio e componentes principais utilizadas neste estudo, foram suficientes para a classificação do objeto pela rede neural artificial, se utilizadas em conjunto. Os experimentos revelam que é necessário usar todas estas variáveis, pois analisar apenas o suporte ou apenas as componentes principais do topo não leva a resultados adequados.

As informações do suporte são fundamentais para separar alguns tipos de poste, principalmente pela sua altura. O raio do suporte, por sua vez, contribui em menor intensidade. Já no que se refere ao topo, nota-se que, embora seja possível analisar a forma do topo separadamente, o resultado depende altamente de sua combinação com as informações da base. A classificação do objeto é somente possível analisando topo e suporte.

Com o objetivo de obter um desempenho satisfatório da RNA, diferentes funções de treinamento foram testadas e apresentaram resultados semelhantes, logo, conclui-se que as amostras escolhidas para o conjunto de treinamento, menos que 20% do total de objetos, foram mais relevantes que as funções utilizadas. Foram classificados 220 objetos em 7 classes com 90% de acerto e utilizando o conjunto com apenas postes e placas, 99% de acerto. Portanto considerou-se vantajosa a utilização das RNA's para classificação de objetos.

Os procedimentos propostos comprovam que é viável detectar e classificar placas de forma automática utilizando a nuvem de pontos oriunda de um sistema laser terrestre móvel, pois apresentou 90% de acerto.

Recomenda-se para este tipo de levantamento um planejamento das feições que desejam ser extraídas para realizá-lo em horário com menos obstrução ou realizar mais passadas de varredura.

A metodologia apresenta uma melhoria para a questão de detecção e classificação de objetos que geralmente são realizadas manualmente. A ampliação do uso dessa metodologia para detectar outros objetos não apresentados nesse estudo, pode ser empregada em trabalhos futuros.

ANEXO 1 - MONOGRAFIA RBMC UFPR



RBMC - Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS Relatório de Informação de Estação UFPR - Curitiba

0. Formulário

Preparado por: Centro de Controle Eng. Kátia Duarte Pereira - RBMC
Data: 05/09/2007
Atualização: 20/10/2009 - Atualização de Firmware

1. Identificação da estação GPS

Nome da Estação: CURITIBA-UFPR
Ident. da Estação: UFPR
Inscrição no Monumento: Não há inscrição
Código Internacional: [93970](#)
Informações Adicionais: -

2. Informação sobre a localização

Cidade: Curitiba
Estado: Paraná
Informações Adicionais: Prisma quadrangular medindo 0,50 m x 0,50 m x 1,20 m de altura, dotado de dispositivo de centragem forçada e extensor. Possui chapa padrão IBGE, cravada na lateral do pilar com a inscrição SAT 91105. Rua 15 de Novembro 1299 - CEP 81531-590 - Curitiba - PR. Nas dependências do Centro Politécnico da Universidade Federal do Paraná.

3. Coordenadas oficiais

3.1. SIRGAS2000 (Época 2000.4)

Coordenadas Geodésicas			
Latitude:	- 25° 26' 54,1269"	Sigma:	0,001 m
Longitude:	- 49° 13' 51,4372"	Sigma:	0,001 m
Alt. Elip.:	925,807 m	Sigma:	0,004 m
Coordenadas Cartesianas			
X:	3.763.751,679 m	Sigma:	0,002 m
Y:	-4.365.113,830 m	Sigma:	0,003 m
Z:	-2.724.404,714 m	Sigma:	0,002 m
Coordenadas Planas (UTM)			
UTM (N):	7.184.223,310 m		
UTM (E):	677.878,515 m		
MC:	-51		

4. Informações do equipamento GNSS

4.1. Receptor

- 4.1.1 Tipo do Receptor - TRIMBLE NETR5
Número de Série - 4651K03576
Versão do Firmware - 3.84 (Principal)
Atualização do Firmware - 20/10/2009 às 00:00 UTC
- 4.1.2 Tipo do Receptor - TRIMBLE NETR5
Número de Série - 4651K03576
Versão do Firmware - 3.50 (Principal)
Data de Instalação - 08/05/2007 às 00:00 UTC



RBMC - Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS
Relatório de Informação de Estação
UFPR - Curitiba

4.2. Antena

4.2.1 Tipo de Antena	- ZEPHYR GNSS GEODETIC MODEL 2 (TRM55971.00)
URL imagem	- http://www.ngs.noaa.gov/ANTCAL/LoadImage?name=TRM55971.00%2BNONE.gif
Número de Série	- 30336616
Altura da Antena (m)	- 0,1000 (distância vertical do topo do marco à base da antena)
Data de Instalação	- 08/05/2007 às 00:00 UTC

5. Informações Complementares

5.1. Para informações técnicas contatar:

Nome: IBGE/DGC/Coordenação de Geodésia
Endereço: Av. Brasil, 15.671, CEP 21.241-051, Rio de Janeiro, RJ
Telefone: (21) 2142-4935
FAX: (21) 2142-4859
Home Page: www.ibge.gov.br
Contato: rbmc@ibge.gov.br

5.2. Para informações sobre comercialização e aquisição de dados contatar:

Nome: Centro de Documentação e Disseminação de Informações - CDDI/IBGE
Endereço: Rua General Canabarro, 706, CEP 20271-201, Rio de Janeiro, RJ
Telefone: 0800-721-8181
Contato: ibge@ibge.gov.br

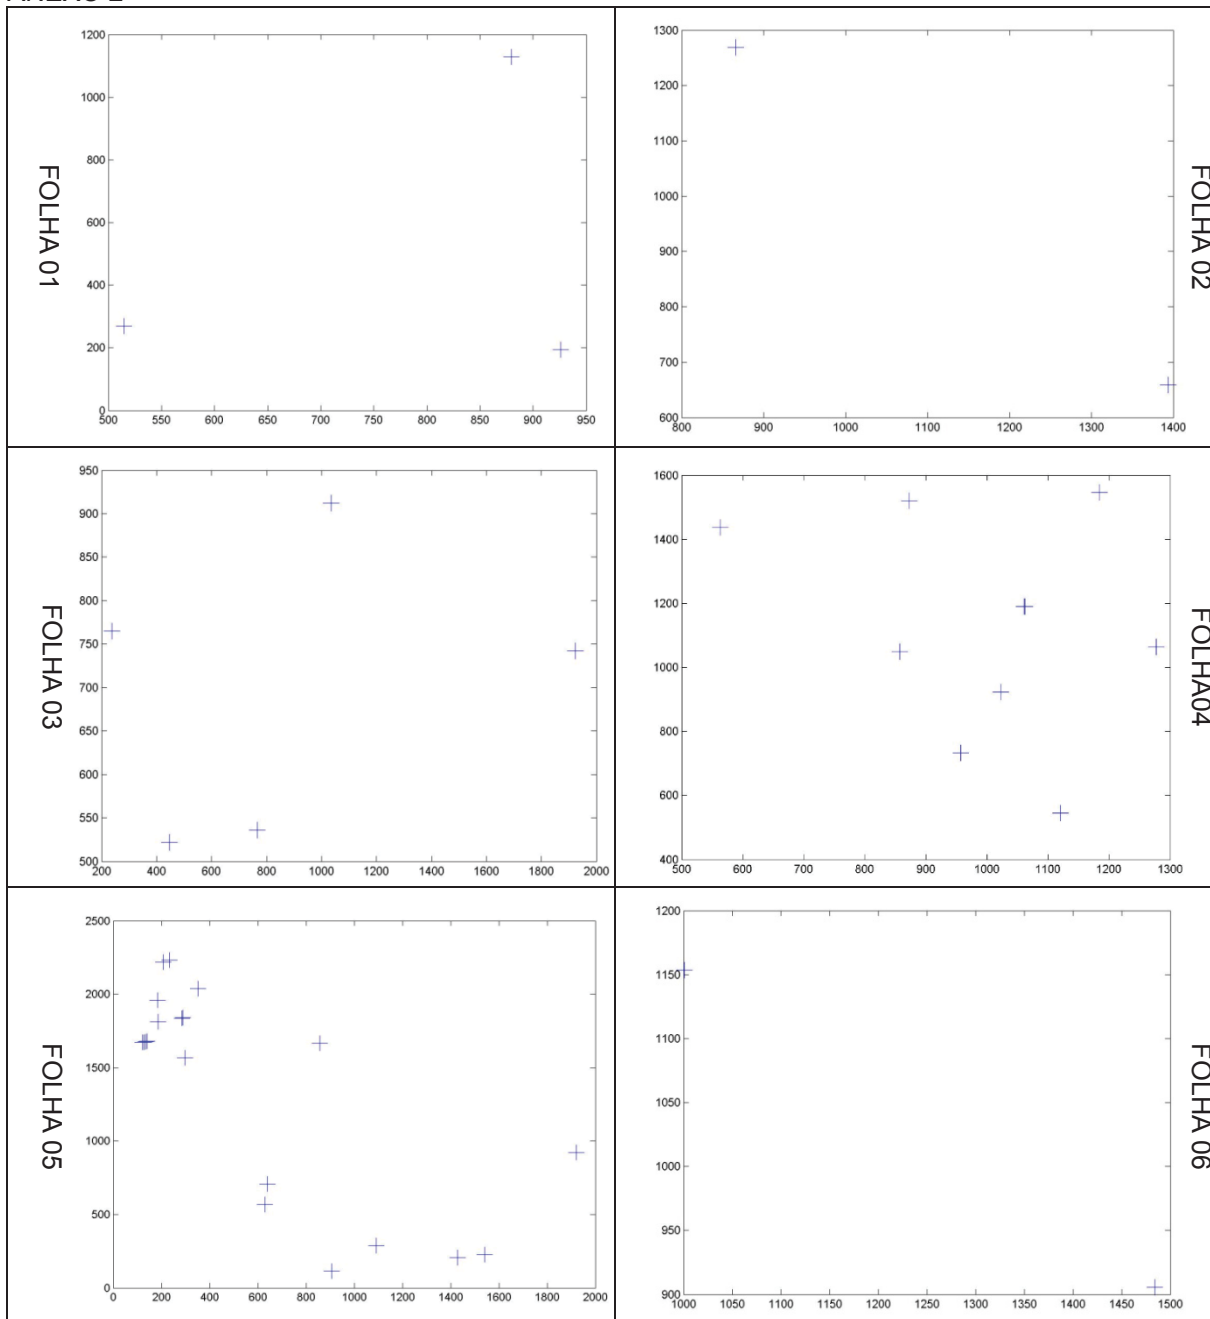
5.3. Instituições participantes

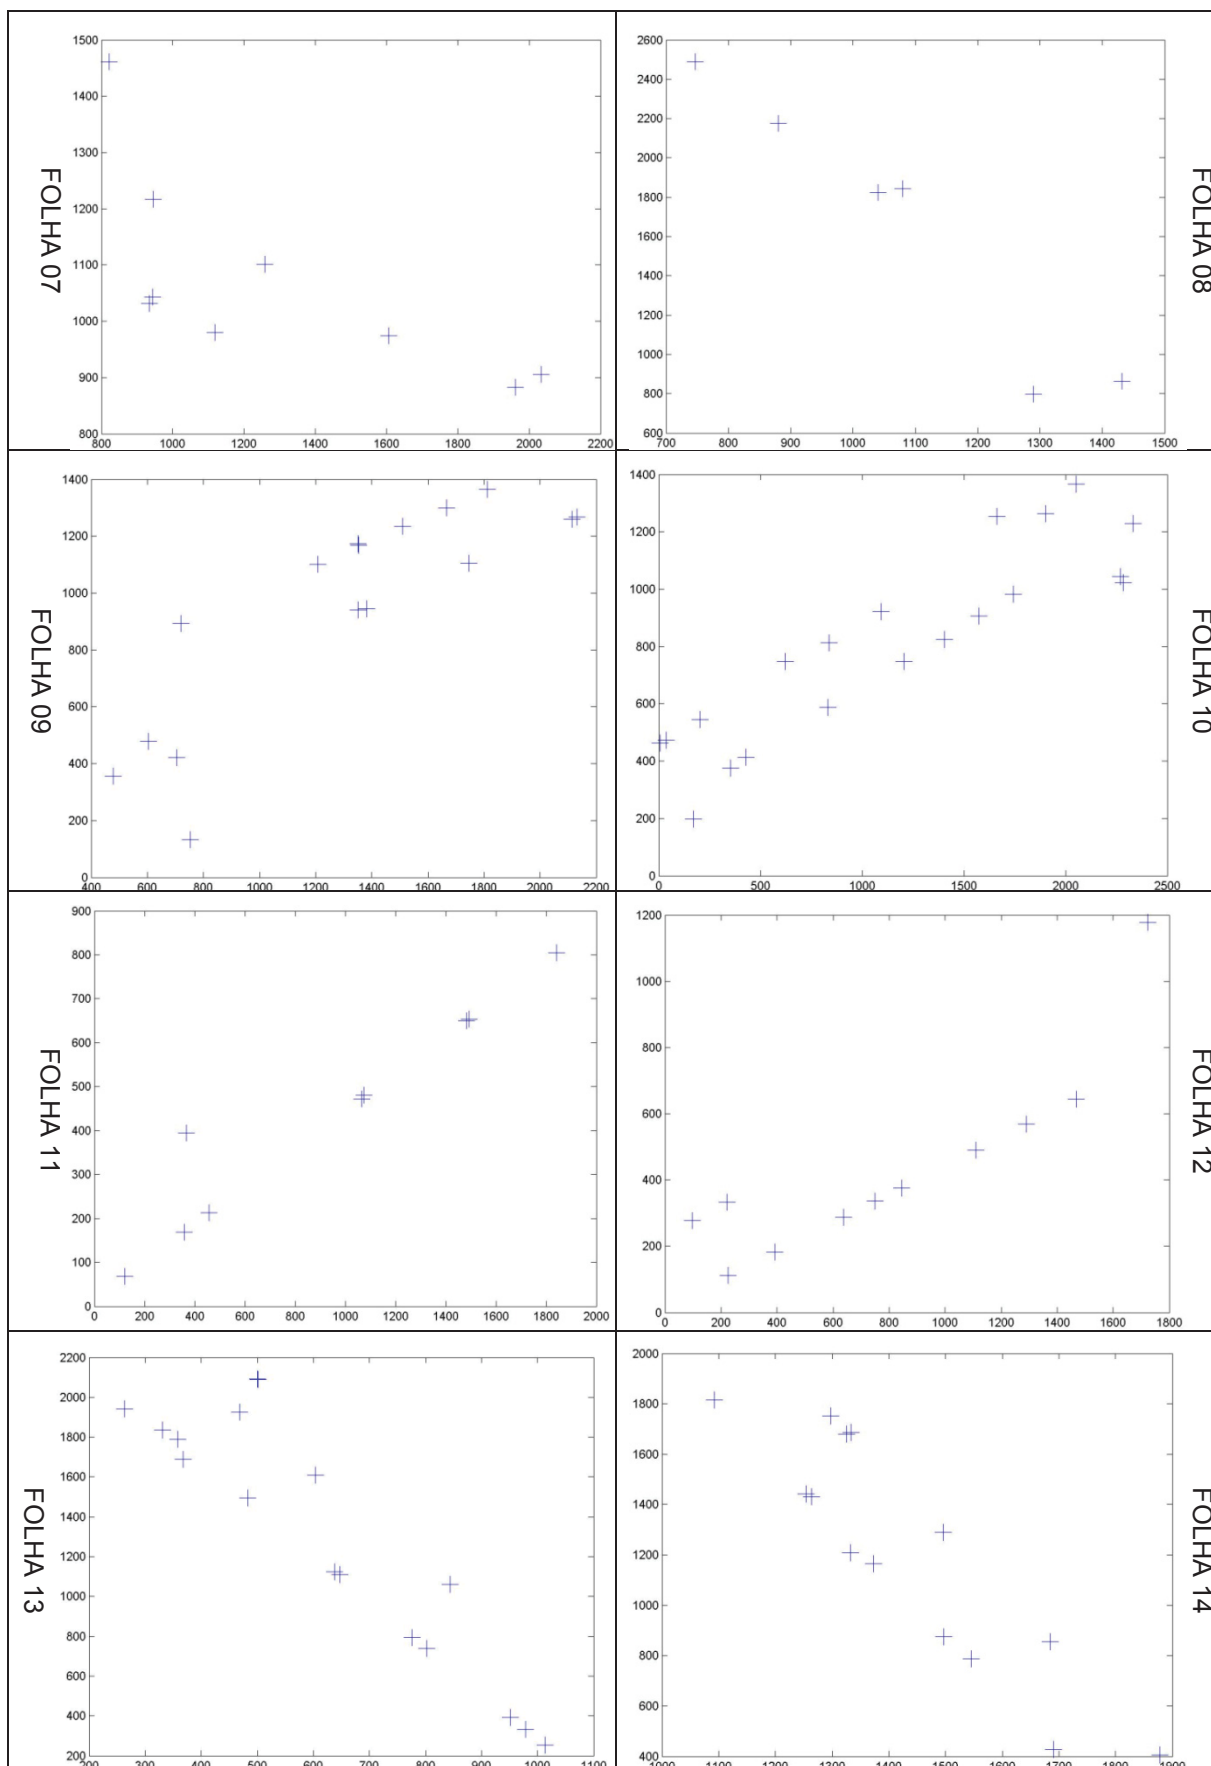
A RBMC conta com o apoio das seguintes instituições:


<http://www.ibge.gov.br/home/geociencias/geodesia/rbmc/parcerias.shtml>

ANEXO 2 - DISTRIBUIÇÃO HORIZONTAL DOS CENTROIDES DOS ELEMENTOS DETECTADOS POR FOLHA.

ANEXO 2 -







REFERÊNCIAS

- AQUINO, A, ARAUJO, A. **Aplicação do Filtro de Kalman a um Sistema de Posicionamento de Veículo Aquático**. V CONNEPI. Instituto Federal de Alagoas. <<http://connepi.ifal.edu.br/ocs/index.php/connepi/CONNEPI2010/paper/viewFile/1607/870>>. Alagoas: 2010
- ANDRADE, Andrea Faria, **Integração de Variáveis Espectrais e Forma na Classificação de Imagens de Alta Resolução Utilizando Redes Neurais Artificiais**. Curitiba: UFPR, 2003.
- BALTSAVIAS, E.P. **Airbone Laser Scanning-Basic Relations And Formulas**, ISPRS Journal of Photogrammetry & Remote Sensing, v.54, n2-3p.64-67, 1999
- BARBER, D., Mills et al. **Geometric Validation Of A Groundbased Mobile Laser Scanning System**, ISPRS Journal of Photogrammetry and Remote Sensing, 2008.
- BEALE, M et al. **Neural Network Toolbox - User Guide, Matlab**. Natick, MA. 2011. <http://www.image.ece.ntua.gr/courses_static/nn/matlab/nnet.pdf>
- BISHENG ,Y et al. **Using Mobile Laser Scanning Data For Features Extraction Of High Accuracy Driving Maps**. State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, Wuhan, China. 2016.
- BRENNER, C., **Extraction of Features from Mobile Laser Scanning Data for Future Driver Assistance Systems**. Advances in GIScience, Lecture Notes in Geoinformation and Cartography. Springer, pp. 25–42, 2009.
- BRETAR, F et al. **Solving The Strip Adjustment Problem Of 3d Airborne Lidar Data**. In Proceedings of the IEEE IGARSS'04, Anchorage, AK, USA, 2004; pp. 4734-4737.
- BROLLY, G., Kiraly, G. et al. **Algorithms For Stem Mapping By Means Of Terrestrial Laser Scanning**. Acta Silvatica et Lignaria Hungarica. 5. pp. 119–130. 2009

BURMAN, H. **Calibration And Orientation Of Airborne Image And Laser Scanner Data** Using Gps And Ins. Ph.D. Dissertation; Sweden: Royal Institute of Technology, Stockholm, 2000; pp. 1-111.

CHEN, Y.-Z et al. **A mobile system combining laserscanners and cameras for urban spatial objects extraction**. Proceedings of the Sixth International Conference on Machine Learning and Cybernetics 2, 1729 –1733, 2007.

FACON, J. **Morfologia Matemática - teoria e exemplos**. Curitiba: PUC, 1996

GOLOVINSKIY, A. et al. **Shape-based recognition of 3D pointclouds in urban environments**. Proceedings of the international conference on computer vision (ICCV), 2154–2161, 2009.

GONZALEZ, R. C; WOODS, R. **Processamento De Imagens Digitais**. São Paulo: Edgard Blücher, 2000. 508p.

GUAN, Haiyan, **Automated Extration of Road Information from Mobile Lidar Scanning Data**. Thesis University of Waterloo, Ontario, Canadá, 2013.

HABIB, A.; BANG, KI, SHIN,S. MITISHITA, E. **Lidar System Self Calibration Using Planar Patches From Photogrammetric Data**. The 5th Internacional Symposium on Mobile Mapping Tecnology, Paduam Italy, 28-31 May, 2007.

HARALICK, R.M., Sternberg, S.R. & Zhuang, X.. Image **Analysis Using Mathematical Morphology**. IEEE Transactions on Pattern Analysis and Machine Intelligence. PAMI-9 (4). pp. 532–550. 1987.

HAYKIN, Simon. **Neural networks and learning machines**. 3rd ed. Upper Saddle River, New Jersey: Pearson Education Inc., 2009. 906 p.

HERNÁNDEZ, J., Matcotegui, B, **Filtering of artifacts and pavement segmentation from mobile Lidar data**. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 38 (Part3/W8), 329–333, 2009.

HOOVER, Rover, R. **3-D laser scanner history.**

http://www.ehow.com/facts_7625254_3dlaser-scanner-history.html. 2012.

JOHN, N. Percepção, Estética e Uso Do Mobiliário Urbano. RS: UFRGS, 2010.

KEMBOI, B.J. **Knowledge-based Detection of Road Furniture Objects in Mobile Laser Scanner (MLS) Data.** University of Twente Faculty of Geo-Information and Earth Observation (ITC), 2014.

KING, A. **Inertial Navigation - Forty Years of Evolution**, GEC Review 1998, 13, 3, 140-149.

KUKKO, A. **Mobile Laser Scanning - System developmente, performance and applications.** Doctoral dissertation. SUOMEN GEODEETTISEN LAITOKSEN JULKAISUJA VERÖFFENTLICHUNGEN DES FINNISCHEN GEODÄTISCHEN INSTITUTES KIRKKONUMMI, 2013.

LI, J et al. **Automated detection of manhole covers using a mobile LiDAR system**, IEEE Proceedings on GiT4NDM, Mississauga, Ontario, Canada, October 9-11, 2013.

MARTIN, A. F. e ROBERT, C. B. **Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography.** Communication of the ACM 24 (6), 381–395, 1981.

NCHRP Report 748. **Guidelines for the Use of Mobile LIDAR in Transportation Applications.** National Cooperative Highway Research Program.

PU, S et al. **Recognizing basic structures from mobile laser scanning data for road inventory studies.** ISPRS Journal of Photogrammetry and Remote Sensing 6(66), S28–S39, 2011.

SHERIF, M. **Detection of Road Furniture from Mobile Terrestrial Laser Scanning** CALGARY, ALBERTA March, 2013 Thesis.

SKALLOUD, J. and Lichti, D., **Rigorous Approach To Bore-Sight Self Calibration In Airborne Laser Scanning**. ISPRS Journal of Photogrammetry and Remote Sensing, 2006. pp 47-59

SKALLOUD, et al. **Towards A More Rigorous Boresight Calibration**, ISPRS International Workshop on Theory Technology and Realities of Inertial/GPS/Sensor Orientation, Castelldefels, 2003.

The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLI-B3, 2016 XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic

TOTH, C.K. Calibrating Airborne Lidar Systems. In Proceedings of ISPRS Commission II Symposium, Xi'an, China, 2002; pp. 475-480

<http://www.asprs.org/committee-general/laser-las-file-format-exchange-activities.html>